Un système multilingual d'interprétation automatique : étape du sous-logiciel "analyse" pour les langues germaniques

Pierre Dimon

UN SYSTÈME MULTILINGUAL D'INTERPRÉTATION AUTOMATIQUE

ÉTAPE DU SOUS-LOGICIEL "ANALYSE" POUR LES LANGUES GERMANIQUES

1ère partie

Thèse [illegible] par Pierre DIMON
pour le Doctorat [illegible]-Lettres

Avant-propos

Il y a plus de quinze ans, le Professeur **Jean-Marie ZEMB** (Collège de France) nous a donné l'occasion de découvrir le Traitement Automatique des Langues Naturelles sous la conduite de **Daniel HERAULT**, directeur du Centre de Recherche Jean Favard et de **Patrice POGNAN**, professeur à l'INALCO. Nous lui devons la découverte d'un domaine passionnant dont la pluridisciplinarité n'est pas le moindre intérêt. Nous lui en sommes particulièrement reconnaissant.

Implanté à Paris et associé au Service de Linguistique de l'Université Pierre et Marie Curie (Paris VI), le Centre de recherche a effectué de nombreux travaux sur le spectre sémantique[1], une idée de **Daniel HERAULT**[2] approfondie depuis 1970 sur le français, le bulgare, le tchèque, le russe, l'allemand et le japonais.

- Collaborant avec l'Académie des Sciences de Bulgarie (Institut de Mathématiques) et sous l'égide du CNRS, le Centre a étudié le spectre sémantique slave (**A. JUDSKANOV**) et précisé la nature d'un spectre sémantique indo-européen, en soulignant l'universalité probable des caractéristiques profondes de sa partie prédicative. Les travaux ont confirmé la possibilité d'obtenir une description convenable du contenu des textes non-littéraires.

- Le soutien de la DRME (Direction des Recherches et Moyens d'Essai) puis de la DRET (Direction des Recherches et Etudes Techniques) pour le Ministère de la Défense a permis d'étendre ces études à d'autres langues avant de concevoir l'Automate de Compréhension Implicite[3] (ACI) qui, partant des propriétés essentielles du spectre sémantique, donnera d'un texte non-littéraire une certaine forme de compréhension.

- Le CNRS[4] a soutenu nos premiers travaux sur l'allemand (module de traitement des mots composés[5] et module verbal).

- Le professeur **Jean-Claude LEJOSNE** (Université de Metz) n'a ménagé ni son temps ni son aide pour le test des modules d'analyse sur l'anglais et le néerlandais. Nous n'avons pas oublié les séances de travail tardives et fructueuses et l'en remercions vivement.

- Sans la bienveillante attention du Président **Jean DAVID**, le Traitement Automatique des Langues Naturelles n'aurait pas pu se développer dans des conditions aussi favorables qu'à la Faculté des Lettres de Metz. Nous le remercions avec gratitude pour ses conseils, ses suggestions et l'intérêt qu'il a bien voulu porter à ce travail, tout au long de son déroulement.

---

(1) Cf. Introduction et chapitre IV

(2) **D. HERAULT** : *Compréhension automatique et spectre sémantique (russe, bulgare, tchèque, français)*, Documents de Linguistique Quantitative n°18, Editions Jean Favard, Paris, 1981

(3) Cf. Introduction et chapitre IV

(4) Action Thématique Programmée : "Mise au point de procédés de simulation de la lecture humaine, avec appréhension automatique du contenu sémantique de textes non-littéraires en langue naturelle".

(5) **P. DIMON** : "Aspects de la composition dans les langues germaniques et réalisation d'un algorithme de localisation des composés pour l'allemand", Thèse de 3ème cycle, Paris III, 1978

- **Patrice POGNAN** a guidé nos premiers pas en informatique. La fréquentation du Centre de Calcul du CNRS à Orsay, de l'Ecole Normale Supérieure (rue D'Ulm) et du laboratoire de la Maison des Sciences de l'Homme sont très certainement à l'origine d'une passion immodérée pour l'informatique et le traitement automatique des Langues Naturelles.

- Nous avons travaillé avec **Daniel HERAULT** pendant plus de treize ans et tenons à l'assurer ici de toute notre reconnaissance pour la richesse et la rigueur de son enseignement. Cette thèse lui doit beaucoup. Il convient de rappeler qu'il a programmé l'environnement du système, réécrit et optimisé le module de traitement des mots composés. Nous avons quant à nous défini l'enchaînement des programmes, rassemblé et organisé toutes les données lingistiques, conçu et programmé l'analyseur morphologique (le verbe, l'adverbe, l'adjectif) et l'analyseur syntaxique.

- Le professeur **Henri ZINGLÉ** (université de Nice) a accepté de relire notre travail. Nous lui sommes reconnaissant d'en avoir examiné le moindre détail et le remercions très sincèrement pour ses critiques constructives.

SOMMAIRE

Résumé

Introduction

Nous définissons le champ de recherche : *la traduction utilitaire.* Liés à l'internationalisation croissante de l'économie, les buts qui lui sont assignés et les besoins afférents appellent de nouveaux moyens parmi lesquels *la Traduction Automatique (TA)* et *la Traduction Assistée par Ordinateur (TAO). Le Traitement Automatique des Langues Naturelles (TALN)* sur un plan plus général, et les progrès de l'Intelligence Artificielle (IA) illustrent le mariage de la linguistique et de l'informatique, moteurs essentiels d'un domaine en pleine expansion : *l'industrie des langues.*

Au coeur de toutes ces activités, la *compréhension automatique*, sous des formes diverses. Une réflexion sur ses mécanismes conduit à cerner les connaissances nécessaires à la compréhension et les choix à opérer pour bâtir un système automatique. Les voies classiques seront explorées et leurs limites soulignées. Nous introduisons ensuite les principes de notre Automate de Compréhension Implicite (ACI), inspiré des travaux du Centre de Recherche Jean Favard. Avec une nouvelle approche de la compréhension, il privilégie l'hypothèse sur les parentés étymologiques des langues européennes.

Chapitre I

Nous tentons de définir la compréhension (1) et d'en déterminer les caractéristiques dans le contexte du traitement automatique. Les difficultés qu'elle rencontre sont répertoriées et présentées dans l'ordre chronologique de leur apparition (1.2). Les éléments qu'elle requiert sont identifiés (1.3), ce qui nous permet d'aborder les théories nécessaires à la représentation de ces connaissances, les modèles de la langue (1.4) et les moyens mis en oeuvre dans le processus de compréhension, les outils d'analyse (1.5). En conclusion, nous nous demandons s'il est vraiment possible de formaliser clairement les langues.

Chapitre II

Pour illustrer les modèles et les outils que nous venons de parcourir, le chapitre II développe la notion d'*industrie des langues* (2.1), et présente la T.A., la T.A.O. et leurs applications essentielles (2.3). Après un bilan des évolutions théoriques et techniques, nous soulignons la difficulté de concevoir une classification cohérente des divers systèmes. Nous préférons distinguer *les systèmes de base* (2.3.2), *les systèmes actuels* (2.3.3), *les prototypes* (2.3.4) et *les projets* (2.3.5). En conclusion, tout en citant d'autres outils (2.4 et 2.5), nous soulignons les limites de ces automates et de leurs performances, malgré les recours de plus en plus importants à la sémantique et à l'Intelligence Artificielle.

Chapitre III

L'analyse des systèmes et l'évolution des conceptions précisent le contexte (3.1) dans lequel nous avons choisi une approche nouvelle avec l'ACI (3.2), un automate de compréhension implicite dont nous définirons les principes et la structure générale. L'automate roman-germanique sera décrit dans son ensemble (3.3), y compris les modules qui n'ont pas encore été réalisés.

Chapitre IV

Nous rappelons les caractéristiques générales de l'automate (4.1), les contextes linguistique et informatique (4.2) puis le décrivons dans le détail, niveau d'analyse par niveau d'analyse, (4.3.1, 4.3.2 et 4.3.3). Le chapitre s'achève sur un listing des résultats complets.

Conclusion

Nous rappelons les réponses classiques aux problèmes que pose la traduction utilitaire et proposons une nouvelle perspective avec l'ACI. Nous dégageons les avantages des principes que nous avons retenus et présentons en illustration, une simulation de l'interprétation telle que doit la générer le module final d'interprétation. Nous donnons ensuite quelques exemples d'extensions de l'ACI sous la forme de sous-produits originaux et exploitables en E.A.O. (annexes I et II).

En ce qui concerne **la bibliographie** et dans un souci de clarté, nous avons tenté de classer les ouvrages et les articles de référence en huit chapitres, qui traduisent la pluridisciplinarité du sujet et l'interdisciplinarité des domaines concernés.

INTRODUCTION

Si nous considérons les langues selon l'expérience quotidienne qu'en a chacun, nous disposons immédiatement d'une première caractérisation, *"impliquée par une activité aussi vieille que les cultures les plus anciennes, attestée jour après jour, indéfiniment reconduite dans sa permanente nécessité au mépris des écueils supposés : la traduction*[1]*"*. Il faut bien admettre, en effet, que tout texte d'une langue peut être traduit approximativement ou parfaitement dans une autre langue. Malgré de nombreux obstacles, chaque langue est *"une sémiotique dans laquelle toutes les autres sémiotiques peuvent être traduites*[2]*"*.

La traduction est l'opération qui consiste à transposer les informations contenues dans un texte source dans un texte cible. Prise dans son sens le plus général, elle pose certains problèmes relatifs à **la signification.** Le sens se coule dans une grande variété de moules formels, *"le sens est partout. Les traducteurs le savent, d'instinct ou d'expérience, qui choisissent une position pour traduire une forme, ou une forme pour traduire un mot*[3]*"*. Il arrive même que la réalité à cerner ne soit pas toujours nette et parfaitement délimitée...

Traduction littéraire, traduction utilitaire

Le langage et la pensée entretiennent des relations obscures. A ce propos, la traduction est un objet d'analyse privilégié, mais c'est tardivement qu'elle a suscité l'intérêt des spécialistes du langage. Le philosophe américain W.M. URBAN[4], les linguistes S.C. GARDINER, O. JESPERSEN, E. SAPIR, VOSSLER et l'ethnologue B. MALINOWSKI[5] lui consacrent une réflexion spécifique. E.A. NIDA[6] rassemble une très grande quantité de problèmes et de solutions formulés du point de vue linguistique. Des besoins de traduction inhérents au statut particulier du Canada ont conduit VINAY et DALBELNET[7] à bâtir une des premières méthodes de traduction fondée sur une base scientifique. Ils mettent en évidence la notion d'unité de traduction, un groupe de mots traduits en bloc parce qu'ils constituent une unité de sens. A partir des années 50, les relations internationales s'amplifient. Les activités de traduction se structurent (Ecoles d'Interprètes, Associations...) et se spécialisent. A.V. FEDOROV[8] et E. CARY[9] étudient les exigences spécifiques de la traduction selon les domaines abordés.

La traduction de la littérature et de la poésie, par exemple, soulève des problèmes considérables. S'il est possible de traduire des structures linguistiques, il est moins évident de traiter des structures métriques, stylistiques ou poétiques, sans parler des connotations culturelles. Le traducteur littéraire n'est pas seulement celui qui réalise l'opération linguistique élémentaire qui consiste à trouver la correspondance la plus exacte des signes d'une langue à l'autre, c'est un amoureux de la communication qui s'efforce de trans-

---

(1) C. HAGEGE : *L'homme de paroles*, Contribution linguistique aux sciences humaines, Le temps des Sciences, Fayard, Paris, 1985

(2) L. HJELMSLEV : *Prolégomènes à une théorie du langage*, Ed. de Minuit, Paris, 1968, p. 138

(3) J.-M. ZEMB : *Vergleichende Grammatik. Französisch-Deutsch*, Teil 1, (Sonderreihe-Vergleichende Grammatiken), Bibliographisches Institut, Mannheim, Dudenverlag, 1978, p. 27

(4) W.M. URBAN : *Language and Thought*, 1939

(5) B. MALINOWSKI : "The Problem of Meaning in Primitive Languages" in *The Meaning of Meaning*, C.K. OGDEN & I.A. RICHARDS, 1946

(6) E.A. NIDA : *Toward a Science of Translating with Special Reference to Principales and Procedures Involved in Bible Translating*, Brill, Leyde, 1964

(7) J.-P. VILNAY, J. DALBELNET : *La stylistique comparée du français et de l'anglais*, Paris, Montréal, Didier, 1958

(8) A. V. FEDOROV : *Vvedenie v teoriju perevoda*, 1954

(9) E. CARY : *La traduction dans le monde moderne*, 1956

mettre une pensée, des émotions, une culture, le chant profond d'un autre idiome. Un ordinateur ne pourra jamais le remplacer dans cette opération intuitive, et quand bien même, jamais sans son aide.

Nous limiterons donc notre champ d'expérimentation à **la traduction de documents techniques et scientifiques**, à la traduction utilitaire autrement dit. L'acquisition et la propagation d'informations pertinentes impliquent en effet pour ces textes, une complexité relativement limitée des structures utilisées, ce qui nous conduit à en préciser les buts.

La traduction utilitaire et ses buts

L'internationalisation de la communication est un phénomène essentiel dans notre société. Si le latin ou l'anglais ont, au cours de notre histoire, permis de véhiculer les informations et de les mettre à la portée d'un grand nombre, la barrière des langues n'en constitue pas moins aujourd'hui un obstacle difficile à surmonter. L'humanité a toujours rêvé d'une société idéale de communication. Elle mesure avec regret la profondeur du fossé qui l'en sépare et ne cesse de croître. Le besoin en information spécialisée souligne les inconvénients d'une disparité que même une institution comme la Communauté Européenne a du mal à résoudre. Le choix d'une langue commune serait une solution. Cependant, les efforts consentis par les organisations internationales (ONU, CEE...) en faveur de la traduction humaine ou automatisée montrent que ce n'est pas une solution à court terme.

Le multilinguisme est une expression de la pluralité et de la richesse de nos civilisations. C'est la seule voie dans laquelle chacun puisse se reconnaître, c'est aussi la chance de maintenir en vie et de continuer à enrichir une civilisation dont nous sommes dépositaires. Au delà des intentions culturelles et *"de la valorisation sans frontière"* d'un *"capital humain considérable*[1]*"*, nous citerons les deux objectifs essentiels que le volume des documents et la multiplicité des langues utilisées assignent à la traduction :

- *Extraire l'information pertinente* : les scientifiques ne pourront jamais plus consacrer suffisamment de temps à la lecture de la littérature spécialisée qui devient trop riche. De plus, il est risqué d'investir un temps précieux pour déchiffrer un texte rédigé dans une langue étrangère que l'on ne maîtrise pas, surtout s'il n'offre en fin de compte que peu d'intérêt.
Les ouvrages scientifiques sont très souvent rédigés en anglais mais la répartition croissante de la technologie dans le monde entame la suprématie d'une langue qui reste tout de même essentielle[2].

En livrant une traduction de faible qualité, un système de traduction rapide et peu coûteux pourrait souvent suffire, dans un premier temps, à l'acquisition des textes concernant le domaine d'activité du lecteur. Dans le pire des cas, ce dernier serait en mesure d'évaluer la nécessité d'un travail plus soigné, par conséquent, plus onéreux. L'expérience montre qu'une traduction juste mais de mauvaise qualité garantit la compréhension du contenu et n'implique pas d'opération supplémentaire. Précisons que le type de texte obtenu (morphologie et syntaxe imparfaites) illustre la liaison en quelque sorte lâche entre correction grammaticale et intelligibilité. Nous développerons cette idée dans le paragraphe 3.2.

---

(1) **R. PETRELLA** : Directeur de l'enseignement, de la culture et du sport, Conseil de l'Europe
(2) **G. KINGSCOTT** : "Applications of Machine Translation". Study for the Commission of the European Communities, septembre 1989, Praetorius Limited, pp. 17-18

- *Assurer la propagation de l'information* : L'industrie, par exemple, qui désire exporter ses produits, doit en général les accompagner d'une documentation rédigée dans la langue de l'acheteur. Les Etats-Unis, dans le passé, ont souvent ignoré cette obligation. Ils commencent à modifier leur politique. D'autres pays, comme l'Allemagne, n'ont pas pu s'offrir ce luxe. La traduction est une pratique qui se répand d'autant plus que les économies s'ouvrent sur l'extérieur. La recherche des marchés étrangers implique, entre autres, une bonne pratique des langues concernées. La difficulté de trouver des traducteurs techniques qualifiés, capables de réaliser rapidement des traductions justes et claires, a suscité un regain d'intérêt pour la traduction automatique, regain dont on peut mesurer l'ampleur lors des grandes manifestations consacrées à la traduction et à ses professionnels[1].

La traduction automatique

Aux deux formes de traduction évoquées plus haut, correspondent deux démarches économiques distinctes :
- Confrontée au problème du prix (le prix de fabrication d'un livre doit être environ le sixième de son prix public de vente hors-taxe pour qu'un éditeur ne perde pas d'argent en l'éditant)[2] et au problème de la gestion des illustrations (le volume de l'iconographie reste constant, alors que le texte peut augmenter de 15 à 20 %), la traduction littéraire est peu rentable. L'éditeur reste cependant libre de ne pas engager la dépense !
- En ce qui concerne la traduction utilitaire, elle s'impose pour les raisons que nous avons indiquées dans le paragraphe précédent. Les besoins sont à la mesure de l'accroissement des échanges commerciaux, scientifiques, industriels, culturels et diplomatiques[3].

---

(1) Parmi les nombreuses manifestations :
- International Conference on the Methodology and Techniques of Machine Translation, Cranfield Institute of Technology, England
- ICCL (International Conference on Computational Linguistics), COLING (Pise/1973, Ottawa/1976, Bergen/1978, Tokyo/1980, Prague/1982, Stanford/1984, Bonn/1986)
- ISSCO Tutorial on Machine Translation (Lugano)
- Annual Meeting of the ACL (Association for Computational Linguistics)
- International Colloquium on Machine Translation, Lexicography and Analysis
- Conference on Theoretical and Methodological Issues in Machine Translation of Natural Languages
- Symposium of the Use of Computers in Literary and Linguistic Research
- FBIS (Foreign Broadcast Information Service, Washington DC) Seminar on Machine Translation
- Annual Convention of the Information Processing Society of Japan
- ASIS (American Society for Information Science) Annual Meeting
- IJCAI International Joint Conference on Artificial Intelligence
- ACL-NRL Conference on Applied Natural Language Processing (Association for Computational Linguistics)

(2) **F. GUERARD** : Responsable des dictionnaires et industries de la langue chez Hachette

(3) Lors de la conférence IFTT à Tokyo en avril 1989, **L. ROLLING** (DGXIII) a évalué le marché mondial de la traduction à 200 millions de pages/an (traductions effectuées par des bureaux de traduction pour le compte de grandes entreprises).
Dans "Machine Translation Technology : on the way to market introduction" in Siemens Review, vol.54, n°6, nov./dec. 1987, **J.A. ALONSO** et **T. SCHNEIDER** parlent de 100 millions de pages pour l'Europe de l'Ouest en 1986.
Le **Translation Bureau of the Canadian Secretary of State** traduit 120 000 pages /an, dont 80% de l'anglais vers le français et vice versa. **DATAQUEST** cite, pour 1986, entre 500 millions et 4,5 milliards de $ selon les secteurs géographiques concernés. **COOPERS et LYBRAND** (Canada, septembre 1987) situent la marché mondial entre 20 et 60 millions de mots (6-18 milliards de FF).
La **CEE** avance le chiffre de 5,6 milliards de $

Le volume des traductions techniques est écrasant[1]. Il suppose un effort considérable pour la saisie, la maintenance et l'utilisation cohérente d'une terminologie convenable.

SECTEUR	MILLIONS DE PAGE/AN	TAUX DE CROISSANCE
commercial-industriel	200	15 %
gouvernemental	100	10 %
scientifique	70	13 %
juridique	35	9 %
divers	60	3-5 %
EUROPE		en M de % US
Allemagne de l'Ouest		1000
Angleterre		650
France		500
Belgique		180
Espagne		200
Italie		140
Suisse		110
Danemark		40
AMERIQUE		en M de % US
E.U.A.		2000
Canada		250
Amérique du Sud		500
Pays francophones (excluant ceux mentionnés)		60

Observatoire des industries de la langue : Actes du séminaire TAO/mars 1989

Si la traduction était par tradition une activité artisanale, elle doit s'adapter à l'évolution du marché. Il devient alors indispensable d'augmenter la productivité du traducteur. L'informatique représente un espoir certain de solution, dans un domaine où la qualité réside bien plus dans la fidélité que dans le style, ce qui est justement l'apanage des systèmes de TALN. L'intérêt est donc grand pour ces applications qui, de la Traduction Automatique (T.A.) et de la Traduction Assistée par Ordinateur (T.A.O.) aux banques de données terminologiques, consacrent le mariage de l'informatique et de la linguistique.

Informatique, linguistique et industrie des langues

L'informatique a d'abord automatisé des processus simples mais les capacités de stockage et de calcul ont augmenté sans cesse pour atteindre un niveau de puissance

---

(1) - Pour M. BORIS dans "Le marché mondial de la traduction" in Décision, n° 246, octobre 1989, p. 66, le marché réel de la France avoisinerait 1,1 milliard de FF et son marché potentiel 1,6 milliard de FF.

- Dans une étude du JEIDA (Japan Electronics Industry Development Association) publiée à l'occasion du MTII (Machine Translation) à Munich en août 1989, le volume total des traductions réalisées au Japon en 1988 est estimé à 200 millions de pages : 65 millions de pages dans les bureaux de traduction, 134 millions de pages dans les entreprises et les administrations. 90% de l'ensemble sont des traductions de l'anglais vers le japonais et vice versa, ce qui représente un montant de 40 milliards de FF pour 1988.

qui suscite d'immenses efforts de recherche. Admirant les performances extraordinaires de l'homme, les techniciens s'intéressent aux sciences humaines et se penchent naturellement sur la manipulation de la langue écrite et orale.
Cet intérêt pour le traitement automatique des langues a donné naissance à une branche particulière de la linguistique. Les recherches en cryptographie imposées par la Seconde Guerre mondiale en sont à l'origine. Elles ont montré que certaines manipulations statistiques dégageaient des propriétés aidant à comprendre des messages en langue naturelle. Certains firent alors le pari très audacieux que l'ordinateur pourrait conduire à la traduction automatique (Memorandum WEAWER)[1]. On s'est aperçu qu'il n'était pas facile de soumettre la langue à une transformation de son matériau pour l'inclure dans des usages automatisables. Les problèmes rencontrés ont stimulé les recherches en linguistique. Une partie des théories et des applications qui en découlent sera l'objet du chapitre I.

- Le traitement de la langue par les machines revêt des formes diverses qui ne peuvent cependant reproduire les compétences langagières de l'homme dans leur étendue, leur raffinement et leur complexité. Les machines chargées de traiter l'information, doivent être capables de manipuler, gérer, conserver, générer et comprendre le langage humain en fonction de structures propres. En dépit des perspectives fascinantes mais à très long terme qu'ouvrent l'Intelligence Artificielle et les Sciences Cognitives, il importe de considérer avant tout les fonctionnalités des traitements linguistiques. Dans le contexte actuel, l'univers techno-économique se développe à un rythme très rapide et appelle une automatisation partielle du premier moyen de communication humain et des applications qui en découlent.

C'est dans ce contexte que l'informatique et la linguistique se rejoignent, on parle d'informatique linguistique, d'automatique linguistique, de linguistique computationnelle. Ces termes voisins ont un objet commun : comprendre et représenter le fonctionnement de la langue parlée et écrite pour en permettre l'interprétation et la génération par des automates. Ce phénomène de convergence concerne également d'autres secteurs scientifiques, l'ergonomie informatique, la logique appliquée, etc. Ces travaux de recherche et de développement pluridisciplinaires ont pris une telle importance qu'ils engendrent une véritable industrie, **l'industrie des langues.**

Les résultats de la recherche en informatique linguistique trouvent en effet une application parfois lucrative dans un ensemble de produits dérivés qui alimentent une nouvelle industrie.

Les champs privilégiés sont :

- L'élaboration des systèmes de dialogue homme-machine au service des automates qui utilisent la langue écrite ou orale pour communiquer avec l'homme.

- La construction d'interfaces en langage naturel pour assurer la "convivialité" des systèmes experts, des systèmes d'E.A.O. (Enseignement Assisté par Ordinateur) et des S.G.B.D. (Systèmes de Gestion de Base de Données).

- Le développement, dans le secteur tertiaire, de tous les outils capables d'automatiser le plus complètement la manipulation de la langue en multipliant les capacités à rédiger, traduire, archiver, consulter, communiquer, en bref, les techniques qui transformeront la bureautique en bureautique "intelligente".

---

(1) W. WEAVER : in *Machine Translation of Languages*, W.N. LOCKE, A.D. BOOTH (eds), MIT Press, 1955

Des grands secteurs comme les banques et les compagnies d'assurances investissent déjà dans ce type de recherche. Il faut cependant espérer que l'industrie restera consciente des énormes difficultés dont nous pensons qu'elles ne pourront jamais être surmontées à 100%, et que, renonçant à des systèmes totalement automatisés, elle saura se fixer des objectifs moins ambitieux. Les analyseurs morphologiques et syntaxiques ont beaucoup progressé. Encore existe-t-il des cas où les connaissances linguistiques ne suffisent pas à la machine pour mener une analyse à terme et lever toutes les ambiguïtés. On sait depuis longtemps qu'elle aurait besoin, pour ce faire, de connaissances particulières concernant notre univers (les données pragmatiques) et le domaine traité.

Compréhension automatique et Automate de compréhension Implicite (ACI)

Il est évident que la machine ne peut traduire sans comprendre. Aussi tenterons nous de définir les connaissances nécessaires à la compréhension avant de développer les méthodes utilisées couramment pour les représenter, les organiser et les utiliser (chapitre I). Les nombreuses applications que nous évoquons dans le chapitre II illustrent l'évolution exemplaire de la Traduction Automatique. La leçon tirée des premiers échecs est précisément qu'il est impossible de traduire sans comprendre. Le poids de la sémantique augmente alors et les résultats gagnent en qualité. Il est cependant de plus en plus difficile d'améliorer la performance des systèmes dont on cerne mieux les limites.

L'histoire déjà riche de la T.A. et de la T.A.O. montre que la complexité et le coût des systèmes croissent plus vite que les gains de qualité. Ceci étant, peut-on aborder le problème dans l'autre sens en recherchant les moyens d'ajuster les résultats aux systèmes possibles, techniquement et financièrement ? En d'autres termes, jusqu'où peut-on se résigner à faire moins bien, tout en "en ayant pour son argent" ? D'autres voies ont été exploitées avec les systèmes à sémantique fermée et les systèmes d'aide à la traduction qui constituent une alternative classique à la Traduction Automatique. Nous avons choisi de nous intéresser à la réduction de la correction du résultat, qui ne garantit plus que l'équivalence cognitive (et encore !), en sacrifiant la correction morphologique et grammaticale. Autrement dit : nous allons tenter de cerner les moyens et donc les coûts d'un "petit nègre intelligible" ?

C'est en privilégiant **la compréhension implicite** et **les parentés étymologiques des langues européennes** que nous avons voulu construire un système d'interprétation automatique (et non pas traduction) de textes non-littéraires. L'horizon de ces recherches est ambitieux. Il s'agit d'extraire d'un texte technique, rédigé dans une langue étrangère, des informations suffisantes pour que le lecteur, spécialiste du domaine traité mais ne connaissant pas la langue source, puisse en reconstituer le contenu. Nous nous écartons légèrement de la Traduction Automatique et de ses écueils. Nous montrerons dans le chapitre III qu'il est possible de reconnaître les éléments nécessaires à ce type de compréhension et que le processus est automatisable.

L'ensemble du travail repose sur deux notions essentielles :

- **La compréhension implicite** : Distinguant *compréhension explicite* et *compréhension implicite*, nous assignons à notre système une fonction de compréhension implicite qui consiste à extraire une information suffisante, à partir d'un texte donné et par des procédés automatiques, pour que tout lecteur ayant une maîtrise du domaine concerné, puisse en déduire une description exacte de ce dont on parle. C'est la compétence du lecteur qui "ferme" la sémantique. La maîtrise du *système dérivationnel de la langue* permettra d'appréhender les racines et leurs modificateurs pour construire le *"spectre sémantique"* du texte analysé et distinguer deux sous-ensembles, l'ossature du texte pratiquement indépendante du sujet traité et les "objets" représentant ce dont parle le texte. Pour que la relation entre le spectre sémantique et la compréhension implicite devienne évidente, il

faut considérer le *spectre sémantique discursif* (obtenu à partir d'un grand nombre de textes non-littéraires) qui donne une idée précise du "noyau prédicatif" de la langue et du système dérivationnel qui lui est associé. Compte tenu de sa stabilité, ce spectre correspond à une "sémantique "fermée". D'un autre côté, on doit lui associer le spectre instable qui correspond à tout texte et dont la sémantique est "ouverte" (racines nominales...). En respectant cette opposition "sémantique ouverte"/"sémantique fermée", des systèmes automatiques indépendants mais compatibles (*le module prédicatif* et *le module hypersémantique*) traiteront les deux types de données.

- **Les parentés étymologiques des langues européennes :** Constatant que le vocabulaire de toute langue est illimité et qu'il devient par conséquent très difficile d'en concevoir la gestion informatique, nous verrons qu'il est possible de le réduire à une combinatoire. Cette réduction s'appuie en partie sur une décomposition des chaînes de caractères conforme aux mécanismes de formation des mots et révèle leur structure étymologique. L'hypothèse de D. HERAULT est que les langues européennes constituent leur vocabulaire en effectuant de nombreux emprunts par reconstruction. Les règles de correspondance des combinatoires sont restées stables de sorte qu'il est possible de générer des mots compréhensibles dans la langue B à partir des structures étymologiques de la langue A, sur la base d'un système de correspondances souvent bi-univoques entre les ensembles de mots simples et les affixes des deux langues. Associées à d'autres résultats, ces reconstructions, plus souvent compréhensibles que correctes, permettront d'obtenir une *interprétation* plutôt qu'une traduction, la correction formelle de la sortie posant le problème des coûts. C'est la correspondance entre les ensembles finis d'éléments des différentes langues, et la nature des programmes d'analyse, indépendants des données, qui confèrent au système ses propriétés *multilinguales*.

Dans le chapitre III, nous situons les travaux du Centre de Recherche Jean Favard dans leur contexte. Après une description des principes fondamentaux de l'Automate de Compréhension Implicite, nous indiquons rapidement ce que doit être sa structure générale, et présentons l'automate germanique-roman, l'objet de notre thèse étant la réalisation des modules d'analyse et leurs résultats.

Dans le chapitre IV, nous détaillerons tous les programmes qui traitent le verbe, l'adjectif, la décomposition des mots et l'analyse syntaxique. Nous joignons l'ensemble des résultats obtenus sur un texte de 149 phrases : *"Brennstoffzellen-Kraftwerke"*.

Le cahier des charges tenait compte des moyens disponibles, humains et financiers. On pourrait parler d'un sain réalisme. Il n'en reste pas moins vrai que si les industriels du TALN reculent souvent devant l'ampleur des investissements financiers et humains à réaliser pour des applications plus ambitieuses, les créneaux qu'ils occupent ont assuré un chiffre d'affaires mondial de 55 millions de dollars pour 1985, et qui progresse, depuis lors, de 100% par an[1]. Cette actualité rehausse l'intérêt de l'ACI (Automate de Compréhension Implicite) dont nous rapellerons les avantages, en conclusion. Le module d'interprétation n'étant pas disponible, nous ne proposerons qu'une simulation de son fonctionnement. Quelques exemples d'applications originales en E.A.O. (Enseignement Assisté par Ordinateur) illustreront une partie des résultats obtenus.

---

(1) A. ABBOU, I. LEFAUCHEUR, T. MEYER : *Les industries de la langue. Les applications industrielles du traitement de la langue par les machines.* (2 volumes), Editions DAICADIF, Paris, septembre 1987

I.

LE TRAITEMENT AUTOMATIQUE DES LANGUES NATURELLES

Dans ce chapitre, nous aborderons le problème du sens et de la compréhension (1.1) et recenserons, en respectant grossièrement la chronologie de leur apparition, les particularités qui rendent le traitement automatique de la langue si difficile (1.2). Ceci nous permettra de définir les connaissances qu'elle requiert (1.3). Pour réaliser des systèmes de traitement automatique, il convient de choisir des formalismes de représentation pour les connaissances qu'utiliseront les ordinateurs. Nous serons donc amenés à présenter les formalismes grammaticaux (les modèles linguistiques, 1.4) et les mécanismes informatiques responsables du processus de compréhension (les outils, 1.5) en les illustrant par quelques exemples.

1.1 Sens et compréhension

Au coeur des problèmes que doit résoudre l'ordinateur, et pour le domaine qui nous intéresse, figurent le sens et la compréhension.

"Que n'a-t-on tenté, pour éviter, ignorer ou expulser le sens ? On aura beau faire, cette tête de méduse est toujours au centre de la langue, fascinant ceux qui la contemplent". Comme le laisse entendre E. BENVENISTE[1], les opérations qu'accomplit l'"énonceur" pour produire et interpréter le sens, sont complexes et très mal connues. Les langues sont d'une diversité typologique considérable et les mécanismes selon lesquels se déploie le sens sont reliés à l'inconscient, inaccessible à l'analyse directe.

---

(1) E. BENVENISTE : "Les niveaux de l'analyse linguistique" in Problèmes de linguistique générale 1, Paris, 1966, Gallimard, Collection Tel, p. 126

- Que signifie *"comprendre"* ? : Pour l'homme, nous sommes loin d'avoir trouvé une réponse précise. Le développement des Sciences Cognitives est récent. Pour la machine, le problème est encore plus complexe. Il faut de plus pouvoir montrer qu'elle a compris ! La compréhension s'effectue à plusieurs niveaux : le mot, la phrase, le texte et le contexte. Le sens d'une phrase, en effet, n'est pas la juxtaposition des sens de chaque mot, celui d'un texte ne peut être réduit à la somme des sens de chaque phrase. Qu'il s'agisse du mot, de la phrase ou du texte, il est parfois impossible de comprendre sans connaître le contexte.

- Comment comprendre que quelque chose n'a pas de sens ? : Nous pensons à des unités lexicales inconnues (mauvaise orthographe, faute de frappe, néologisme...) ou à des constructions syntaxiques inédites. S'il est difficile de définir cette notion, il nous semble par contre plus simple d'en étudier quelques caractéristiques, reflétant chacune un degré divers de compréhension. Voici quelques critères :

- La capacité de répondre à une question, de façon appropriée.

ex. - *Paul est-il le frère de Michel ?*
- *Non.* (réponse appropriée)
- *Non, c'est Jean.* (réponse plus appropriée)
- *Non. Paul est le frère de Julien.*

- La capacité de paraphraser, d'exprimer autrement une idée.

- La capacité de faire des inférences en tirant des conséquences probables de ce qui a été dit.

- La capacité de traduire d'une langue à l'autre, ce qui suppose une certaine capacité d'abstraction reflétant la possibilité de représenter à un niveau sémantique ou conceptuel les différentes relations causales ou de dépendance entre les constituants d'une phrase ou d'un texte, en tenant le moins compte possible de la "forme de surface".

- La capacité de résoudre des problèmes de référence. Une part importante de nos capacités de compréhension consiste à réaliser qu'un même objet ou un même personnage apparaît sous plusieurs formes (pronominalisation...).

- La réussite du test de TURING[1] : un opérateur communique tantôt avec un ordinateur, tantôt avec un être humain, sans connaître l'identité du destinataire. S'il ne peut reconnaître l'ordinateur au bout d'un moment, d'après les réponses, c'est que le programme est "intelligent".

Le rejet du sens a été poussé à son stade ultime par le structuralisme américain[2]. On conçoit dès lors les espoirs insensés placés dans le développement d'une Traduction Automatique asémantique. Les ennuis sont apparus dès les premiers travaux.

1.2 Les obstacles à la compréhension

La compréhension automatique se heurte à un ensemble de difficultés considérables, liées essentiellement aux propriétés des Langues Naturelles. Nous allons les passer en revue, selon une chronologie approximative de leur apparition.

---

(1) Ce thème est repris dans D. HOFSTADTER : *Gödel, Escher, Bach, les Brins d'une Guirlande Eternelle*, Interéditions, 1988, Paris, traduit de l'américain par J. HENRY et R. French

(2) L. BLOOMFIELD : Language, New York, 1967, (Traduction française, 1970, Payot, Paris)

1946-1955 : La morphologie et les statistiques -> le mot

Dès l'apparition de l'ordinateur, les recherches de W. WEAVER[1] aux Etats-Unis et de W. N. LOCKE en Angleterre accréditent la faisabilité d'une analyse morphologique automatique qui pourrait mener à la traduction, pour autant que des traitements statistiques permettent d'accéder à un niveau sémantique suffisant. La première conférence sur la Traduction Automatique est organisée par BAR-HILLEL au MIT en 1952. L'optimisme lié aux nombreux travaux sur la recherche dans les dictionnaires sera vite déçu. Considérer la traduction comme une substitution de mots et un éventuel réordonnancement est une vision trop simpliste qui oublie les traits essentiels que partagent toutes les langues sous une forme ou sous une autre.
Ces caractéristiques sont telles qu'il n'y a pas de correspondance précise entre l'ensemble des mots ou des phrases et l'ensemble des sens. Au niveau des mots, on peut citer plusieurs écueils :
- L'homonymie : c'est la relation qui existe entre deux ou plusieurs formes ayant le même signifiant, mais des signifiés différents. On distingue les homophones (même son, sens différents) qui ne nous concernent pas ici et les homographes (même graphie, sens différents).
- La polysémie : Le signifiant présente plusieurs signifiés. Les signifiants différents sont perçus comme présentant des traits sémantiques communs.
Homonymie et polysémie sont à l'origine des nombreuses difficultés que le traitement automatique regroupe sous le terme d'*ambiguïtés*.
ex : *les poules du couvent couvent*
il est uni
Se fondant sur des exemples tels que :
The box is in the pen (la boîte est dans le parc)
The pen is in the box (le stylo est dans la boîte)
BAR-HILLEL[2] montrera que des connaissances sur le contexte sont indispensables. Il pose ainsi la question fondamentale de la représentation des connaissances et de leur utilisation et le considère comme insoluble.

Au vu des résultats obtenus, le Rapport ALPAC[3] condamne brutalement les recherches. Il convient cependant de citer les travaux de Mc CARTHY, MINSKY, NEWELL et SIMON qui pensent que l'on pourra écrire des programmes "intelligents" dans la mesure où il sera possible de décrire précisément les aspects de l'intelligence pour qu'une machine puisse la simuler. Tandis que les travaux sur la Traduction Automatique sont pratiquement stoppés, les chercheurs du MIT développent des systèmes (SIR, BASEBALL, STUDENT, ELIZA...) qui relancent les recherches sur la compréhension automatique du langage. Les domaines traités sont très limités et la syntaxe inexistante.

1955-1970 : La syntaxe -> la phrase

De son côté, N. CHOMSKY[4] développe la théorie des grammaires formelles qui débouche sur des traitements purements syntaxiques. Les évolutions sont nombreuses mais les interprétations syntaxiques possibles sont trop riches pour qu'elles se prêtent

---

(1) W. WEAVER : "Translation" in W.N. LOCKE, A.D. BOOTH (eds.), *Machine Translation of Languages*, Wieley, New York, pp. 15-23, 1955
(2) Y. BAR-HILLEL : *Language and Information*, Addison Wesley, Reading Masss., 1964
(3) ALPAC : *Language and Machines ; Computers in Translation and Linguistics*, Report by the Automatic Language Processing Advisory National Research Council, National Academy of Sciences, Publication 1416, Washington D.C., 1966
(4) N. CHOMSKY : Syntactic Structures, Mouton, La Hague, 1957

au traitement automatique. S. PETRICK[1] cite le cas d'une phrase de 17 mots donnant 572 interprétations syntaxiques possibles.
Les phénomènes que nous rencontrons au niveau des mots se retrouvent ici, au niveau de la phrase :

- L'allotaxie : les formes syntaxiques différentes peuvent s'interpréter de la même façon (une phrase à l'actif a le même sens qu'au passif)

- l'homotaxie : la même forme syntaxique peut avoir des interprétations différentes.
La maîtrise de la structure du langage est essentielle. A une période particulièrement féconde succède cependant le désenchantement des chercheurs qui ont placé trop d'espoir dans la recherche syntaxique et surestimé son poids.

Dans la deuxième moitié de cette période, on peut citer, en ce qui concerne les univers limités, la logique des prédicats du premier ordre qui permet d'interpréter la structure syntaxique et donne de bons résultats :

- programme de dialogue avec un robot, de L. S. COLES[2]
- travaux de T. WINOGRAD[3], et, plus récemment, de A. COLMERAUER[4] et P. SABATIER[5] avec Prolog.

1968 : La sémantique et le contexte

De nombreux systèmes voient le jour, qui éludent les difficultés en limitant les domaines et en réduisant la syntaxe à sa plus simple expression. De nouvelles équipes décident alors d'étudier les aspects sémantiques. Il faut citer les grammaires de cas de FILLMORE[6] qui fondent l'analyse de la phrase sur le sens des rapports verbe-objet plutôt que sur la structure même. QUILLIAN[7] propose de représenter le sens des mots et des phrases à l'aide des réseaux sémantiques. Les approches sont ensuite essentiellement sémantiques (SHANK[8], WILKS[9]), le rôle de la syntaxe est réduit.
Les limites des programmes alors conçus résident dans les difficultés à relier les phrases d'un texte. On découvre l'importance du contexte et les avantages que procurerait une bonne connaissance du domaine traité. Les problèmes sont :

---

(1) S. PETRICK : "Transformational Analysis", in *Natural Language Processing*, Rustin, New York, Academic Press, pp. 27-41
(2) L.S. COLES : "An On-line Question-Answering System with Natural Language and Pictorial Input"; *Proc. of the 23rd A.C.M. National Conference*, 1968
(3) T. WINOGRAD : "Procedures as a Representation for Data in a Computer Program for Understanding Natural Language", *Cognitive Psychology*, 3(1), pp. 1-191, Jan. 1972,
(4) A. COLMERAUER : "Les grammaires de métamorphose" in L. BOLC (ed.) ; *Natural Language Communication with Computer : Lecture notes in Computer Science*, n°63, Springer Verlag, pp. 133-189, 1978
(5) P. SABATIER : "Puzzle Grammars" in *Prog. Log. 84*, Actes du colloque "Compréhension du langage naturel et programmation en logique", Rennes, sept. 1984, North Holland, 1985
(6) C. FILLMORE : "The Case for Case", in *Universals in Linguistic Theory*, Bach & Harms, Chicago, Holt, Rinehart and Winston, 1968, pp. 1-90
(7) R. QUILLIAN : "Semantic Memory", in *Semantic Information Processing*, Minsky, MIT Press, Cambridge Mass, 1968, pp. 227-270
(8) R. SCHANK : "Conceptual Dependency : a Theory of Natural Language Understanding", Cognitive Psychology, Vol. 3 (4), pp. 552-631
(9) Y. WILKS : "An artificial Intelligence Approach to Machine Translation", in *Computer Models of Thought and Language*, Schank & Colby, Freeman, San Francisco, 1973, pp. 114-151

- L'anaphore : c'est la relation entre une forme et une forme à laquelle on renvoie dans le discours. (le pronom - *Le juge se lève, il est calme* -), (la référence définie - *le juge se lève, cet homme calme...* -)

- L'implicite : C'est la partie du message que l'auditeur peut reconstituer. Les recherches qui traitent ce domaine se multiplient en 1974. La logique du premier ordre n'est pas adaptée au traitement des univers complexes. C'est la représentation des connaissances qui focalise les énergies et suscite l'intérêt des informaticiens pour les psychologues. Les recherches intègrent la psychologie cognitive et l'informatique. R.C. SCHANK[1,2,3] identifie les connaissances nécessaires dans un système de compréhension du langage, M. MINSKY[4] propose un cadre général de représentation des connaissances avec les "frames". On peut noter l'apparition d'autres disciplines, telles la neurologie (N. GESCHWIND[5]), la philosophie et la métaphysique (D.C. DENNET[6], S. TORRANCE[7])..

Les premières tentatives de Traduction Automatique ont échoué parce qu'elles ne reposaient pas sur la compréhension du texte et manipulaient les mots du langage comme n'importe quel autre symbole, autrement dit, sans tenir compte du fait que le langage est un outil de communication entre êtres humains, destiné à véhiculer certaines idées. A la difficulté d'incorporer des dictionnaires complets des langues à traduire, (le russe et l'anglais, initialement), se sont ajoutés les problèmes de polysémie et de syntaxe propres à chaque langue. Les premiers résultats étaient loin du mot à mot, le programme ne proposant qu'une liste de mots possibles. Si Y. BAR HILLEL[8] montre alors que la traduction a besoin de connaissances encyclopédiques, il faut se rappeler qu'à l'époque, on ne savait pas encore comment implanter une grammaire dans un ordinateur, que les systèmes étaient rédigés en langage machine et que la récursivité n'était pas autorisée par la majorité des langages de programmation. Partant du fait qu'il était impossible de traduire sans comprendre, on cherche alors les moyens de représenter la signification d'une phrase ou d'un texte, et de lever les ambiguïtés possibles de certains mots, ce qui nécessite parfois d'utiliser le contexte et de disposer peut-être d'un modèle du monde.

Deux approches illustrent ces préoccupations :

- Le texte d'entrée est traduit en une structure arborescente qui représente la construction syntaxique de la phrase, augmentée éventuellement de quelques informations sémantiques extraites d'un dictionnaire. Cette structure est ensuite manipulée par une

---

(1) R.C. SCHANK (ed.) : *Conceptual Information Processing* ; North Holland, 1975
(2) R.C. SCHANK, R.P. ABELSON : *Scripts, Plans, Goals and Understanding*, Lawrence Erlbaum Ass., 1977
(3) R.C. SCHANK : "Reminding and Memory Organisation : an Introduction to MOP's" in W. LEHNERT, M. RINGLE (eds.), *Strategies for Natural Language Processing*, Lawrence Erlbaum Ass., 1982
(4) M. MINSKY : "A Framework for Representing Knowledge" in P.H. WINSTON (ed.), *The psychology of Computer Vision*, Mc Graw Hill, pp. 211-277, 1975
(5) N. GESCHWIND : "Neurological Knowledge and Complex Behaviour" in D.A. NORMAN (ed.), *Perspectives on Cognitive Science*, Lawrence Erlbaum Ass., 1981
(6) D.C. DENNET : *Brainstorm : Philosophical Essays on Mind and Psychology*, Harvester Press, 1979
(7) S. TORRANCE (ed.) : *The Mind and the Machine : Philosophical Aspects of Artificial Intelligence*, Ellis Horwood, 1984
(8) Y. BAR HILLEL : *Language and Information*, Addison Wesley, Reading Mass, 1964

grammaire de transfert[1,2] pour générer une phrase syntaxiquement correcte dans la langue cible.

- La seconde approche accorde moins d'intérêt à la syntaxe. Elle vise en revanche une représentation conceptuelle des phrases beaucoup plus fine et implique une compréhension plus profonde du texte à traduire (Y. WILKS[3] et R. SCHANK).

1.3 Les connaissances requises pour la compréhension

Si l'on considère les divers types de connaissances qui interviennent dans les mécanismes de compréhension, on reconnaît les niveaux classiques de l'analyse avec :

- Le vocabulaire et sa structure (lexique et morphologie)
- L'ordre des mots dans la phrase (syntaxe)
- Les aspects sémantiques
- La structure du discours, les relations entre phrases
- Les données pragmatiques

Il est clair qu'une bonne compréhension dépendra de la maîtrise des éléments que nous venons d'énumérer et que ces éléments ne seront pas seulement utilisés pour l'analyse.

1. Les connaissances morphologiques : Les mots apparaissent dans la phrase sous des formes diverses (accords grammaticaux, conjugaison...). L'analyse doit reconnaître qu'il s'agit d'un même mot. Deux méthodes sont possibles.

- On relève toutes les formes dans le dictionnaire, en répétant certaines informations, (ex. petit, petite, petits, petites). La taille des fichiers devient rédhibitoire pour les langues riches en flexions à moins de limiter les entrées en leur associant un module de génération des formes fléchies.
- La reconstruction de la forme de référence à chaque occurence du mot.

Dans les deux cas, il faudra utiliser la forme "canonique" du mot (infinitif pour le verbe, masculin singulier pour le nom, l'adjectif...), disposer du système dérivationnel de la langue et des règles qui régissent les combinaisons qu'il engendre. Pour la phrase *le secrétaire vole des livres*, nous obtenons les résultats suivants :

le	article défini masculin singulier, pronom
secrétaire	nom masculin singulier
vole	voler (transitif, 1ère et 3ème personne présent indicatif, ...)
	voler (intransitif, 1ère et 3ème personne présent indicatif, ...)
des	article indéfini (masculin/féminin pluriel), article contracté,...
livres	nom masculin pluriel, nom féminin pluriel

A ce niveau, les ambiguïtés sont nombreuses.

---

(1) R. KITTREDGE, L. BOURBEAU, P. ISABELLE : "Design and Implementation of an English-French Transfer Grammar" in Coling 76, Ottawa
(2) C. BOITET : "Problèmes actuels en T.A. : un essai de réponse" in Coling 76, Ottawa
(3) Y. WILKS : "An Artificial Intelligence Approach to Machine Translation" in *Computer Models of Thought and Language*, SCHANK et COLBY (Eds.), San Francisco, 1973, Freeman, PP. 114-151

2. Les connaissances syntaxiques : Une fois que les entrées dans le dictionnaire ont été reconnues, il faut éclaircir leur agencement dans la phrase, distinguer le ou les sujets, les compléments, le groupe verbal... Ces connaissances qui décrivent des relations formelles entre des catégories de mot, sans tenir compte de leur valeur sémantique constituent la grammaire.
Reprenons l'exemple précédent. L'application des règles de grammaire va nous indiquer, sans tenir compte du sens, que la phrase est correcte si *le* est un article et *vole* transitif. Cette étape nous aura donc permis de réduire le nombre des ambiguïtés.

3. Les connaissances sémantiques : Une phrase peut être correcte mais n'avoir aucun sens. Nous avons besoins des connaissances sémantiques qui précisent les relations entre les mots de la langue et le monde (réel ou spécifique d'un domaine traité), sans référence au narrateur. Ce sont les aspects explicites du sens. On dira par exemple que *boire* fait intervenir un agent et un objet, que l'agent peut être animé ou inanimé, que l'objet est liquide.....

Pour notre phrase, le *secrétaire* est un employé ou un rapace, *livres* est une mesure de poids, une monnaie anglaise ou un objet de lecture. *Voler* (transitif) implique un objet concret, ce qui permet d'éliminer *livre* mesure de poids. La levée de cette ambiguïté permet de préciser la nature de *des*.
Il reste quatre possibilités. Cependant, il faut préciser que le nombre d'interprétations dépend des traits retenus par le système. Dans le traitement d'un domaine très spécifique, il serait inutile de conserver *secrétaire* objet inanimé... Il n'en reste pas moins qu'à ce stade de l'"analyse", un homme ou un animal ont dérobé un livre ou des billets de banque.

4. Les connaissances pragmatiques : Nous avons maintenant besoin d'informations sur la situation évoquée, pour opérer les choix conformes au contexte et aux réalités. Ce sont les connaissances pragmatiques qui expriment les aspects implicites du sens. La compréhension dépend de la situation de communication et de la façon dont l'énoncé s'intègre dans notre représentation du monde. On retrouve la composante pragmatico-interprétative (influence de la situation sur le sens pour obtenir la signification) que R. MARTIN[1] ajoute à la composante sémantico-logique (sens littéral). H.P. GRICE[2] définit également la signification globale d'un énoncé comme une combinaison du sens des mots qui le composent (sens lexical), avec des implications conventionnelles (pragmatique intentionnelle) et des implications non conventionnelles.

Nous venons d'évoquer les connaissances nécessaires à la compréhension d'un énoncé, partant du principe que cette compréhension était préalable à l'opération de traduction. C'est cette optique qui explique les nombreuses incursions du chapitre dans le domaine de l'Intelligence Artificielle. Pour construire des systèmes de Traduction Automatique ou de Traduction Assistée par Ordinateur basés sur la compréhension, les chercheurs doivent effectuer des choix à différents niveaux. Nous rappelons ces niveaux et les possibilités qui lui correspondent.

- Comme nous venons de le voir dans 1.3, il faut disposer de connaissances externes par rapport aux textes traités. Ces connaissances devront être formalisées pour que l'ordinateur puisse les manipuler. Il reste à choisir le système formel qui sera utilisé.

---

(1) R. MARTIN : *Inférence, antonymie et paraphrase*, Paris, Klincksieck, 1976
(2) H.P. GRICE : *Utterer's Meanig, Sentence Meaning and Word Meaning*, Foundations of Language, 4, 1968, pp. 225-242

- Qu'il s'agisse de l'étape d'analyse ou d'opérations ultérieures affectées à la compréhension, il convient de construire les algorithmes de traitement, c'est à dire les mécanismes informatiques.

Dans ce qui suit, nous étudierons les moyens disponibles pour résoudre les deux types de problème :

Dans 1.4 , nous verrons les formalismes grammaticaux et leur influence importante sur la forme des représentations internes. Les grammaires traditionnelles ne se prêtant pas facilement au traitement informatique, nous parlerons d'abord des grammaires formelles (1.4.3.1) et de leurs évolutions, les grammaires transformationnelles (1.4.3.2) avec la théorie standard, la théorie standard étendue, la théorie des traces, qui privilégient les aspects syntaxiques. Parmi les extensions intéressantes figurent les grammaires syntagmatiques généralisées (elles tentent de traiter les aspects sémantiques) et les grammaires logiques (grammaires de métamorphose et grammaires à clauses définies) qui permettent de construire des représentations internes plus variées et concernent davantage les aspects de mise en oeuvre sur ordinateur. C'est la raison pour laquelle nous avons préféré les traiter avec les outils (1.5.8). Les grammaires de cas (1.4.3.3) accentuent le rôle de la sémantique. Les grammaires systémiques (1.4.3.5) accordent la priorité au contexte d'utilisation du langage et ne le considèrent plus comme un système formel isolé. Nous terminerons par les grammaires fonctionnelles (1.4.3.6) qui intègrent des aspects sémantiques et constituent actuellement, pour cette raison, un axe de recherche important. Elles expriment l'importance accrue du lexique dans les descriptions linguistiques, comme dans les travaux de M. GROSS et de MEL'CUK.

Dans 1.5 , nous aborderons les processus informatiques qui utilisent les représentations basées sur les modèles présentés dans la partie précédente et qui concernent schématiquement l'analyse syntaxico-sémantique de la phrase pour la construction d'une représentation interne de la phrase.

1.4 Les modèles de la langue

Nous ne nous intéresserons qu'au traitement du langage naturel écrit. Les applications sont multiples et l'apparition d'une "*industrie de la langue*" confirme l'intérêt économique qu'il suscite. La présentation sommaire de ce vaste domaine, articulée sur les théories linguistiques, les techniques informatiques et leurs applications soulignera la difficulté des problèmes rencontrés et l'aspect pluridisciplinaire de ces recherches. Nous ne tiendrons pas compte des modèles inutilisés par l'informatique et ne mentionnerons des applications distinctes de la T.A. et de la T.A.O. qu'en abordant les outils d'application (1.5).

Que l'on examine les moyens qui permettent au dialogue homme-machine de se rapprocher d'un dialogue normal, ou que l'on considère les réflexions que l'être humain a pu consacrer à son propre langage, depuis l'antiquité déjà, sous les angles de la grammaire, de la philosophie, de la linguistique... sans oublier l'informatique qui introduit une façon de poser les questions et d'exprimer les réponses susceptibles de renouveler notre pensée sur le langage, nous constatons que l'informatique entretient des rapports complexes avec le langage naturel. Les modèles choisis pour l'interprétation de textes en langage naturel sont issus d'autres disciplines que l'informatique. Cette dernière ne doit cependant pas être réduite à un simple outil, elle peut également fournir des modèles.

1.4.1 Les niveaux

Le traitement informatique du langage naturel sous-tend un ensemble d'hypothèses sur ce qu'est le langage. Ces hypothèses se traduisent par le choix d'***un modèle*** dont nous admettrons que le but est d'expliquer comment on passe d'une chaîne de caractères à sa signification. Il est désormais habituel, en linguistique, de considérer cinq niveaux de la langue écrite :

- **le niveau morphologique** : on reconnaît les mots sous les différentes formes liées à leur rôle dans la phrase (déclinaison, conjugaison...).

- **le niveau lexical** : permet d'associer le mot reconnu aux informations dont on dispose sur ce mot.

- **le niveau syntaxique** : traduit l'agencement des mots dans la phrase.

- **le niveau sémantique** : correspond à la représentation du sens des mots.

- **le niveau pragmatique** : élargit le contexte et concerne les aspects implicites du sens. C'est ce que le locuteur fait du langage.

Les traitements qui sont effectués à chaque niveau sont spécifiques. La conception des systèmes est de plus en plus souvent modulaire, de sorte que l'on retrouve dans les réalisations informatiques une division des tâches identique à celle des linguistes.

- La plupart des systèmes sont conçus pour un enchaînement séquentiel des traitements, du morphologique au pragmatique, avec des possibilités limitées de retour en arrière.
- Une autre conception se développe dans le sens d'une intégration des différents traitements. Les réalisations ne sont pas très nombreuses, nous y reviendrons par la suite.

Si les deux premiers niveaux ne présentent pas de difficultés importantes, il en va autrement pour les niveaux supérieurs (syntaxe, sémantique,et pragmatique), ainsi définis par C. W. MORRIS[1], dans la lignée des travaux de C. S. PEIRCE.

1.4.2 Les modèles sans syntaxe

Une vision réductrice classe les mots d'un texte en deux catégories, ceux qui portent une signification et les autres. Une hypothèse encore plus forte affirme que l'ordre des mots n'influe pas sur la signification d'un texte. Un texte se réduit alors à un ensemble de mots clés. Des équivalences permettent de savoir si le texte répond positivement ou négativement à une requête exprimée comme une expression booléenne.

Ce type d'approche est à proscrire lorsque le traitement s'applique à un domaine sémantique ouvert ou à des constructions complexes. Il convient par contre à certaines applications comme l'interrogation de bases de données de petite taille. Il est en effet possible de substituer à une requête formulée en langage naturel:

"Pouvez-vous m'indiquer les horaires de train au départ de Paris pour la ville de Metz ?"
une liste de mots clés *"Horaire, train, Paris, Metz"*.

---

(1) C.W. MORRIS : "Foundations of the Theory of Signs" in O. NEURATH, R. CARNAP, C.W. MORRIS (eds.), *Encyclopaedia of Unified Science*, University of Chicago Press, 1939

Le choix de ces mots clés n'est pas toujours évident. Il est parfois nécessaire de lever l'ambiguïté de certains termes et d'interpréter correctement l'ordre des mots.

1.4.3 Les modèles avec syntaxe

Les autres modèles admettent que les phrases ont une structure et que cette structure joue un rôle important pour la compréhension.

1.4.3.1. Les grammaires formelles

Un langage formel construit sur un alphabet est un sous-ensemble (potentiellement infini) de toutes les chaînes formées des éléments de cet alphabet.
Le premier concept est celui du vocabulaire V, composé de deux sous-ensembles finis et disjoints:

- L'alphabet V_T (vocabulaire terminal) avec un nombre fini de symboles qui figurent les mots du texte tels qu'ils ont été identifiés par les traitements morpho-lexicaux.

- L'ensemble V_N (vocabulaire non terminal) des symboles nécessaires à la description de cette langue ("les variables" ou "les catégories syntaxiques"). La phrase est ainsi mieux structurée que dans les grammaires traditionnelles où l'on ne formule que deux niveaux : les propositions et les catégories lexicales.
- V^*, le monoïde libre construit sur V_T, est l'ensemble des chaînes finies formées en combinant les symboles terminaux de toutes les façons possibles. Un langage est défini, par conséquent, comme un sous-ensemble de V^*.

Pour illustrer la structure interne d'une phrase, on utilise l'opération de réécriture (règles de réécriture ou règles de production). Un ensemble de ces règles substitue à un axiome S (Sentence) ou P (Phrase) des chaînes composées d'éléments terminaux et/ou auxiliaires.

La règle P ——> GN + GV indique qu'une phrase (P) peut être composée d'un syntagme nominal GN suivi d'un syntagme verbal GV.

+ est le symbole de la concaténation.
——> signifie qu'il faut réécrire le symbole de gauche en utilisant les symboles de droite.

L'ensemble de règles de réécriture peut se noter :
$R = \{ X \longrightarrow Y \}$ avec $X, Y \in V^*$ et $X \neq 0$

On peut définir une grammaire formelle par le quadruplet :
$G = (V_N, V_T, R, P)$

Le langage engendré par la grammaire G est l'ensemble de toutes les chaînes terminales que l'on peut dériver de S ou de P en appliquant toutes les séquences possibles des règles de réécriture.

On peut classer les grammaires selon plusieurs critères. Nous reprendrons la classification de N. CHOMSKY[1] pour les quatre types de grammaires formelles, numérotées de 0 à 3.

---

(1) M. GROSS, A. LENTIN : *Notions sur les grammaires formelles*, Gauthier-Villars, Paris, 1970

1.4.3.1.1 Les grammaires de type 3

Ce sont des grammaires régulières. Si l'on note X et Y les éléments non terminaux et a un élément terminal

($X,Y \in V_N$, $a \in V_T$) on peut définir les règles:

X ——> a+Y ou X ——> a grammaire régulière à gauche
X ——> Y+a ou X ——> a grammaire régulière à droite

Les langages décrits par ces grammaires sont caractérisés par la possibilité de rajouter itérativement un nombre arbitraire de fois, une séquence de mots, si la grammaire le prévoit. On peut montrer que le mécanisme de génération correspond à un automate d'états finis. On les appelle pour cette raison *grammaires d'états finis*. Au cours de la génération, il suffit de connaître l'état dans lequel on se trouve pour terminer la phrase correctement.
Tout langage fini est régulier, il peut être décrit par une grammaire régulière. Dans une application concrète, l'alphabet est fini, tout comme la longueur des phrases à analyser. On peut donc utiliser un modèle régulier mais les modèles de ce genre risquent d'être énormes et reflètent mal la structure des phrases. Ce type de grammaire ne peut pas traiter certains aspects comme les structures imbriquées ou parenthésées, d'où son insuffisance. On peut cependant les utiliser pour des cas simples, car elles se comportent comme des outils d'analyse déterministe qui traitent une phrase dans un temps proportionnel à sa longueur.
Pour tenir compte des régularités sous-jacentes des langues, on est amené à considérer le formalisme suivant dans la hiérarchie définie par N. CHOMSKY.

1.4.3.1.2 Les grammaires de type 2

Le membre gauche de la règle ne peut être qu'un symbole non terminal (appartenant à V_N). Parce que ces règles n'expriment aucune contrainte sur le membre droit, la grammaire est dite *indépendante du contexte*, ou *à contexte libre*. Le membre gauche peut être réécrit sous la forme du membre droit, indépendamment des symboles qui l'entourent.

Soit la grammaire composée des deux règles suivantes :

P ——> a+P+b

P ——> a+b

Elle engendre un nombre quelconque de "a" suivi d'un nombre quelconque de "b". On a besoin de connaître le début de la phrase pour la terminer correctement.

exemple :

Règle 1	P --->	GN+GV
Règle 2	GN --->	ART+NOM
Règle 3	GV --->	(AUX)+VERBE+GN
Règle 4	AUX --->	peut/doit/veut/...
Règle 5	VERBE --->	lire/manger/acheter/...
Règle 6	ART --->	le/la/les/un/une/des/...
Règle 7	NOM --->	homme/femme/garçon/soupe/...

L'application successive de R1, R2, R3, R2, R6, R7, R4, R5 permet de construire la phrase *La dame veut acheter une voiture.*
Cette grammaire permet une représentation graphique de l'application des règles à la manière des schémas parenthésés de R. S. WELLS[1] et des "boîtes" de C. F. HOCKETT[2].

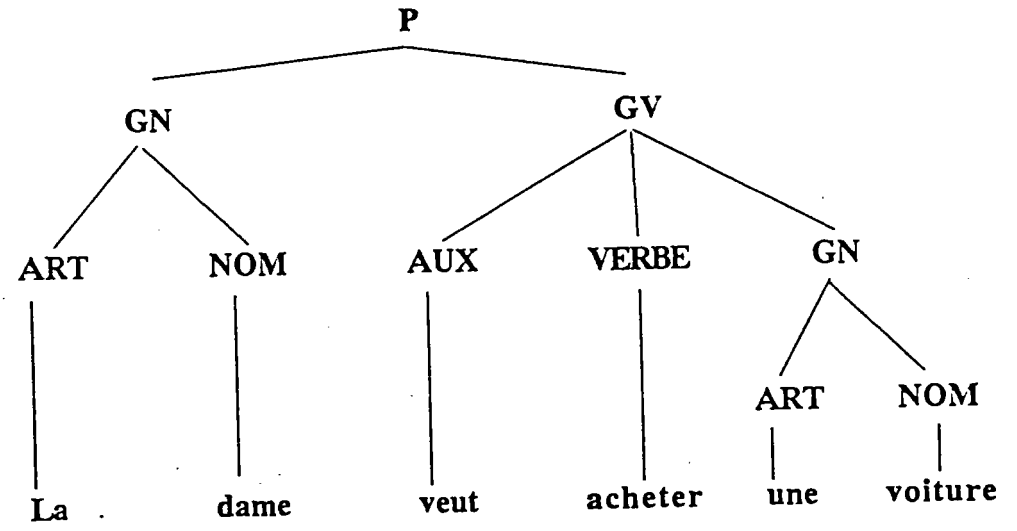

Ce type de représentation illustre l'impossibilité de traiter des constituants discontinus (il faudrait que les branches se croisent) mais peut rendre compte des phénomènes d'enchâssement. Ce formalisme correspond à la notion d'automate à pile, ce qui est assez simple à transcrire sur un plan informatique (paragraphe 1.5.3.3).

Les grammaires à contexte libre étaient réputées insuffisantes pour décrire les langues naturelles. Les travaux de M. SALKOFF[3] et de G. GAZDAR[4] ont tenté d'y remédier, mais elles mettent alors en œuvre un nombre de règles (de l'ordre du milliard) qui les rend inadéquates au traitement informatique. La prise en compte d'un aspect linguistique nouveau entraîne une croissance exponentielle du nombre de règles.

Bien que des modèles à contexte libre regroupant un petit nombre de règles soient adaptés à des sous-ensembles restreints du langage naturel, le formalisme suivant de N. CHOMSKY semble présenter de nouveaux avantages.

1.4.3.1.3 Les grammaires de type 1

Les règles $X \dashrightarrow Y$ $(X,Y \in V^*, X \neq 0)$ sont telles que la chaîne Y contient au moins autant de symboles que la chaîne X.

On peut écrire les règles sous une forme équivalente :
$u+x+v \dashrightarrow u+y+v$ $(u,v,y \in V^*, x \in V_N, y \neq 0)$

---

(1) R.S. WELLS : "Constituants immédiats" in *Langage*, n°20, pp. 61-100, 1970
(2) C.F. HOCKETT : *A Course in Modern Linguistics*, Macmillan, New York
(3) M. SALKOFF : "Analyse syntaxique du français : grammaire en chaîne", *Etudes en linguistiue française et générale*, n°2, John Benjamins, Amsterdam, 1979
(4) G. GAZDAR : "Phase Structure Grammars and Naturel Languages", *Proc. of the 8th IJCAI*, Karlsruhe, pp. 536-565, aug. 1983

Ceci signifie que **x** peut se réécrire en **y** dans le contexte **u—v**, autrement dit, s'ils sont tous deux entourés de **u** et de **v**.

Ces grammaires sont appelées, pour cette raison, *sensibles au contexte* ou *grammaires contextuelles*. La première forme signifie que le nombre de symboles de la chaîne ne peut qu'augmenter. Si nous considérons une phrase de longueur **n**, le fait de ne pas l'avoir rencontrée après avoir généré toutes les chaînes de longueur au moins égale à n implique qu'on ne pourra pas la rencontrer par la suite, elle n'appartient donc pas au langage. On peut avoir recours, par conséquent, à un automate linéaire borné qui utilise une mémoire proportionnelle à la longueur de la phrase à reconnaître.

La difficulté de traiter facilement les allotaxies et les constituants discontinus, la possibilité de ne pas reconnaître toutes les homotaxies, l'extrême complexité dans la description des règles sont autant de raisons qui ont conduit au rejet des grammaires contextuelles. Ce modèle n'est pas utilisé sous cette forme pour l'analyse des langues bien que certains mécanismes employés lui soient en fait équivalents. La mise en oeuvre dans des programmes reste très délicate. Il est souvent préférable d'accroître la puissance générative des grammaires non contextuelles pour les rendre équivalentes aux grammaires contextuelles. C'est l'approche qui a été développée avec les réseaux de transition augmentés (ATN) que nous aborderons dans la présentation des outils d'analyse.

La résolution des problèmes liés au sens, (rejet des phrases ayant une structure correcte mais un sens inadmissible) conduit, pour ces grammaires contextuelles à développer des traits sémantiques, dans le module syntaxique. Il a fallu modifier le modèle pour que ces traits puissent fonctionner en liaison avec la notion de transformation. Dans ce cas, ils sont considérés comme des marqueurs qui indiquent les transformations que subira la structure.

1.4.3.1.4 Les grammaires de type 0

Il s'agit de systèmes non limités et trop peu structurés (systèmes de réécriture généraux ou règles générales de réécriture), puisque l'on n'introduit aucune contrainte sur la forme des règles de réécriture et que les langages correspondants peuvent être analysés par une machine de TURING générale[1]. Cette grammaire est par conséquent difficilement utilisable. Nous citons quelques explications en 1.5.3.3.

1.4.3.2 Les grammaires transformationnelles

Issues de la linguistique structurale américaine, ces grammaires génératives sont connues essentiellement à travers les publications de N. CHOMSKY.

Simple mécanisme génératif syntaxique, le modèle devient une théorie complète du langage avec des visées plus cognitives.

---

(1) A. TURING : "On Compatible Numbers with an Application to the Entscheidungsproblem", *Actes London mathematical society*, Séries 2, 42, pp. 230-265, 1936

1.4.3.2.1 La théorie standard

N. CHOMSKY[1] intègre une composante sémantique et introduit des transformations. Deux étapes aboutissent à la formulation d'une idée :

- la création d'une structure profonde qui, seule, peut être interprétée sémantiquement.
- la transformation de cette structure profonde en une structure de surface liée directement à la forme de l'énoncé.

Les connaissances syntaxiques s'articulent en trois volets :

- une grammaire formelle qui, complétée par le lexique, constitue la base du module syntaxique et permet d'engendrer des structures abstraites, appelées structures profondes (correspondant pratiquement à des phrases noyaux). On leur associe l'arbre de dérivation correspondant.

- des règles de transformation qui s'appliquent à ces arbres de dérivation et permettent d'engendrer toutes les formes possibles de phrases grâce à différents mécanismes manipulant les chaînes terminales pour produire les structures de surface.

- les règles morpho-phonémiques engendrent à partir de la structure de surface la suite des caractères et des phonèmes qui constituent la phrase.

Un module sémantique interprète la structure profonde et produit le sens de la phrase générée. On constate, dans ce modèle, que tous les éléments nécessaires au module sémantique appartiennent à la structure profonde. On peut douter de l'autonomie de la syntaxe que ce modèle implique. Il n'est pas évident d'autre part qu'il soit possible de décrire la compétence linguistique sans tenir compte des mécanismes de production et de compréhension.

1.4.3.2.2 La transformation

Z. HARRIS[2,3] a été le premier à utiliser la transformation de façon opératoire. Une transformation se décompose en :

- une description structurelle DS (forme qui correspond à la partie de l'arbre à laquelle on applique la transformation et qui indique une suite d'éléments voisins, sans préciser leurs relations exactes dans l'arbre).

- des changements structurels CS (les opérations à appliquer sur l'arbre, conformément à une règle).

- des conditions (pour définir les cas dans lesquels les règles s'appliquent).

Une règle s'appliquera à un sous-arbre à condition qu'il contienne la suite de noeuds indiquée par DS. La présence d'éléments avant ou après est sans importance.

---

(1) N. CHOMSKY : *Structures syntaxiques*, Le Seuil, Paris, 1959
(2) Z. HARRIS : "Co-occurence and Transformation in Linguistic Structure" in *Language*, 33, 3, pp. 283-340, 1957
(3) Z. HARRIS : "Linguistic Transformation for Information Retrieval", *International Conference on Scientific Information*, Vol. 2, p. 158, 1958

La présence d'éléments supplémentaires entre les éléments indiqués est par contre interdite. Quand il y a correspondance avec le sous-arbre, les changements structurels (CS) interviennent comme une série de transformations élémentaires (suppression, substitution, adjonction) pour aboutir à la transformation de la structure profonde en une structure de surface.

On distingue deux catégories de règles :

- les règles obligatoires qui arrangent les éléments terminaux et sans lesquelles on ne peut obtenir une phrase correcte. Elles sont marquées par des traits dans la structure profonde.
- les règles facultatives, qu'il n'est pas indispensable d'appliquer pour obtenir une phrase correcte et qui traduisent les possibilités de paraphrasage. Elles peuvent engendrer d'autres phrases correctes à partir de règles obligatoires (négation, forme interrogative, forme passive...).

Le statut des règles varie plus ou moins selon les traits reconnus par la grammaire et l'influence que peuvent ou ne peuvent pas exercer les transformations sur le sens (théorie standard, théorie standard étendue...). Dans le cas présent, il ne peut y avoir modification du sens puisque la composante sémantique n'agit que sur la structure profonde.
Une série de transformations ne peut pas toujours s'effectuer dans n'importe quel ordre. Une transformation peut, en intervenant prématurément, modifier une structure, la rendre impropre à une autre transformation ou fausser les résultats. On est ainsi contraint de fixer un ordre d'application, par paire de règles. On trouve un excellent exemple pour l'anglais dans A. AKMAJIAN, F. HENY[1].

1.4.3.2.3 Les grammaires en chaîne

Z. HARRIS[2] a introduit la notion de transformation, mais sans structure profonde et sans traitement sémantique, dans le but principal de décrire les relations de paraphrase entre les formes de surface de phrases attestées.
Basée sur une étude distributionnelle de la langue[3], sa théorie consiste à considérer tout énoncé comme l'adjonction de chaînes auxiliaires à une chaîne centrale élémentaire (le plus petit segment de phrase acceptable et significatif que l'on peut isoler dans l'énoncé).

Ces chaînes centrales élémentaires constituent le noyau de cette grammaire. Une chaîne centrale se décrit par une quinzaine de formules, du type $\Sigma_t V \Omega$ (sujet, verbe fléchi, objet). La séquence de catégories grammaticales indique une structure où les catégories pourront être remplacées par des mots qui en font partie.

On définit ensuite des chaînes d'ajout (groupes prépositionnels, adverbes, propositions subordonnées) également décrites par des formules, qui pourront s'insérer entre deux éléments de chaîne.
Les phrases de la langue sont ainsi des chaînes dérivées des chaînes élémentaires par insertion de chaînes d'ajout. Il est cependant nécessaire de limiter les combinaisons possibles en imposant des restrictions le plus souvent sémantiques, à la combinaison de catégories syntaxiques autorisées par les formules.

---

(1) A. AKMAJIAN, F. HENY : *An Introduction to the Principles of Transformational Syntax*, Cambridge Mass., MIT press, 1975
(2) Z. HARRIS : *Structures mathématiques du langage*, Paris, Dunod, 1971
(3) Z. HARRIS : *Methods in Structural Linguistics*, Chicago, 1951

Ces restrictions sont souvent complexes. Il n'est pas toujours facile de les formaliser. Pour le verbe *regarder*, on limitera la classe des sujets possibles à celle des êtres vivants, et la classe des objets à celle des éléments concrets. L'étude des relations qu'entretiennent plusiers phrases entre elles, dans le contexte de l'acceptabilité et de l'ambiguïté conduit à construire une grammaire de listes (travaux de M. GROSS). La grammaire en chaîne apporte une souplesse importante pour exprimer l'ordre relatif des constituants de la phrase. Son rôle essentiel est de décrire les phénomènes de surface sans utiliser la notion de structure profonde. Son intérêt n'est évident que dans le cas d'une analyse purement syntaxique (analyseur automatique de l'anglais de N. SAGER et analyseur d'intitulés en français par J.H. JAYEZ, p. 74).

1.4.3.2.4 Extensions de la théorie standard

Le modèle transformationnel tel que le définit la théorie standard repose sur des hypothèses qui concernent des structures abstraites. Dans la théorie standard étendue et la théorie des traces, Z. HARRIS cherche à maîtriser la surpuissance d'un modèle assimilé à une grammaire de type 0. P.S. PETERS et R.W. RICHTIE[1,2] ont remis en cause son universalité.

1.4.3.2.4.1 La théorie standard étendue

Elle reconnaît l'influence des transformations sur l'interprétation sémantique[3]. Le module sémantique doit s'appliquer à l'ensemble des arbres engendrés par les transformations, à partir de la structure profonde (N. CHOMSKY[4]). Pour traiter les exceptions et les irrégularités en ce qui concerne les mots à insérer dans la structure de surface, N. CHOMSKY propose d'ajouter l'étape d'insertion lexicale avant les processus de transformation, ce qui a pour résultat d'aboutir à deux types de règles :
- la production d'une séquence préterminale de marqueurs grammaticaux, de marqueurs de transformations et de catégories lexicales.
- Ces dernières sont remplacées par des mots grâce aux règles d'insertion lexicale et l'on obtient la séquence terminale, ou structure de surface.

Peu de programmes utilisent actuellement la théorie standard étendue. On peut citer W. PLATH et F. DAMEREAU avec le système REQUEST.

1.4.3.2.4.2 La théorie des traces

Dans cette variation de la théorie précédente, N. CHOMSKY[5] propose que les deux modules sémantique et phonologique n'agissent que sur la structure de surface, qui contient des traces reflétant les informations de la structure profonde et des transformations. L'hypothèse selon laquelle on pourrait engendrer n'importe quel langage à partir d'une grammaire de base ordinaire, avec des transformations appropriées, a engendré des modèles voisins où les tranformations ont été remplacées par d'autres mécanismes. Des difficultés théoriques et le fait surtout que la grammaire transformationnelle suppose que, lors de l'analyse, on applique les transformations à l'envers pour retrouver

---

(1) P.S. PETERS, R.W. RICHTIE : "On the Generative Power of Transformational Grammars", *Information Science*, 6, pp. 49-83, 1973
(2) P.S. PETERS, R.W. RICHTIE : "A Note of the Universal Base Hypothesis", *Jounal of Linguistics*, 5, pp. 150-152, 1969
(3) N. CHOMSKY : *Aspects de la théorie syntaxique*, Le Seuil, Paris, 1971
(4) N. CHOMSKY : "Deep Structure, Surface Structure and Semantic Interpretation" in Steinberg & Jakobovits, pp. 183-216, 1971
(5) N. CHOMSKY : *Reflexions on Language*, Pantheon, New Jersey, 1975, (traduction française chez Payot, Paris, 1977)

une structure profonde, expliquent, outre la complexité de mise en œuvre, que l'informatique et le modèle n'aient pas fait bon ménage. Il faut bien avouer, également, qu'il est beaucoup plus important de modéliser la compréhension que de reconnaître si une phrase a une structure syntaxique correcte. Un des buts que poursuivent les travaux de Traduction Automatique et de Traduction Assistée par Ordinateur est bien d'interpréter un texte. Les théories qui introduisent toujours plus de notions sémantiques seront probablement mieux adaptées au traitement automatique des langues naturelles. Les travaux les plus significatifs sont ici ceux de M. MARCUS[1] avec son analyseur syntaxique déterministe.

1.4.2.4.3 Les grammaires syntagmatiques généralisées

La complexité croissante des règles et des contraintes nécessaires n'a pas résolu tous les problèmes dont certains ont pu, cependant, trouver une solution, sans recours aux transformations. L'idée de les abandonner a conduit aux grammaires lexicales fonctionnelles avec le modèle de J. BRESNAN[2] el le modèle de G. GAZDAR[3] qui introduisent les notions de traits avec les catégories dérivées, les méta-règles et les règles sémantiques. Si les traits tiennent compte des aspects contextuels dans les grammaires de type 1, ils s'appliquent ici à chaque nœud et sont organisés hiérarchiquement, à la façon des grammaires systémiques (1.5.3.5). La notion de catégorie dérivée permet de réserver une place pour un constituant qui n'est pas précisé et de générer ainsi directement une structure de surface, sans utiliser de transformations mais avec les informations suffisantes pour retrouver l'équivalent d'une structure profonde. Les méta-règles augmentent la puissance de création des règles sans influencer la puissance du formalisme lui-même, en fonctionnant dans une certaine mesure comme les transformations mais en opérant sur les règles et non sur les arbres. Le but des règles sémantiques est de créer une structure logique qui représente le sens de la phrase. La création de cette structure est réalisée en parallèle avec la structure syntaxique.
A chaque règle syntaxique est liée une règle sémantique, l'application de la première dépendant de l'applicabilité de la seconde. Cette méthode est identique au fonctionnement de la grammaire du logicien R. MONTAGUE qui laisse de côté les problèmes syntaxiques des "transformationnalistes" pour s'attacher aux aspects sémantiques. A chaque mot sont associées une catégorie syntaxique et une catégorie sémantique logique. R. MONTAGUE[4] substitue au calcul des prédicats du premier ordre une grammaire de catégories avec des règles syntaxiques et sémantiques interdépendantes. Les avantages de ces règles sémantiques sont évidents pour l'interprétation de certaines ambiguïtés, les problèmes de grammaticalité, de la quantification, des constituants discontinus... La théorie de G. GAZDAR[5] s'écarte des grammaires syntagmatiques au fil des modifications concernant :
- les catégories syntaxiques considérées comme des ensembles non ordonnés de traits décrits par des couples <attribut - valeur>

---

(1) M. MARCUS : *A Theory of syntactic recognition for natural language*, Cambridge Mass., MIT Press, 1980
(2) J. BRESNAN , R. KAPLAN : "Lexical Functional Grammars ; a Formal System for Grammatical Representation" in *The mental Representation of Grammatical Relations*, J. BRESNAN (ed.), MIT Press, 1981, Cambridge Mass.
(3) G. GAZDAR, G. PULLUM, I. SAG : "A Phrase Structure Grammar of the English Auxiliary System", 1980, in *The Nature of Syntactic Representation*, B. JACOBSON, G. PULLUM, Dordrecht, 1982
(4) R. MONTAGUE : "English as a Formal Language", repris dans *Formal Philosophy*, THOMASON, Yale University Press, p. 188
(5) G. GAZDAR, E. KLEIN, G. PULLUM, I. SAG : *Generalized Phrase Structure Grammar*, Basil Blackwell, Oxford, 1985

- les règles parmi lesquelles il faut distinguer les règles de dominance immédiate (DI) et les déclarations de précédence linéaire (PL).
Le fonctionnement des méta-règles est de plus en plus limité et les éloigne progressivement des transformations.

On mesurera le poids de la syntaxe et des théories de N. CHOMSKY dans le système SYSTRAN (2.3.3.2.9). Pour une application de grammaire indépendante du contexte, nous renvoyons au système TAUM-AVIATION (3.3.3.3.7.2). En ce qui concerne les grammaires transformationnelles, nous verrons TAUM-METEO (2.3.3.3.7.1), METAL (2.3.2.3) et pour les grammaires syntagmatiques généralisées, ATLAS I (2.3.3.2.1), HICATS (2.3.3.2.2) et METAL (2.3.3.2.5).

1.4.3.3 Grammaires de cas

Le modèle transformationnel est capable de traduire les similarités entre les structures profondes de phrases présentant des structures de surface différentes. Il est incapable de résoudre un certain nombre de problèmes comme , par exemple, la conjonction des sujets : (1) *Pierre lave le linge.* (2) *Sophie lave le linge.*
Pierre et Sophie lavent le linge serait une transformation correcte.
Considérons une autre phrase :
(3) *la lessive lave le linge.*
Une tranformation du même type sur (2) et (3) donnerait :
Sophie et la lessive lavent le linge.
Ce qui n'est pas acceptable. Les règles syntaxiques sont équivalentes mais les règles sémantiques sont différentes.

1.4.3.3.1 La théorie de C. FILLMORE

Le modèle casuel que définit C. FILLMORE[1], plutôt que d'attribuer une structure profonde identique aux deux phrases, distingue les sujets par leurs traits. La structure profonde se décompose en un verbe relié à des groupes syntaxiques par des cas (agent, instrument, datif, factitif, locatif, objet). Ce système est complété par une liste de modalités. Les cas (relations casuelles) décrivent les fonctions sémantiques générales des arguments d'un prédicat. C. FILLMORE pensait réunir un ensemble de cas capables de définir des représentations indépendantes de la langue d'origine et qu'il supposait en nombre restreint. Les diverses versions du modèle[2,3] traduisent les difficulté qu'il a rencontrées. Si nous reprenons l'exemple précédent, la structure de cas résout le problème. Les groupes nominaux ne peuvent être liés par une conjonction que s'ils jouent le même cas sémantique par rapport au verbe.
Pierre et *Sophie* sont les agents de l'action exprimée dans (1) et (2).
La lessive est l'instrument.
Parce que les structures profondes font apparaître avec plus de netteté le sens de la phrase, les spécialistes en Intelligence Artificielle et en Traitement Automatique des Langues Naturelles ont manifesté beaucoup d'intérêt pour cette théorie. Les propriétés responsables de son succès en fixent également les limites. S'il est simple de limiter à une dizaine de cas les relations entre un groupe nominal et un verbe, on appauvrit le registre des significations représentables.

---

(1) C. FILLMORE : "The Case for Case" in *Universals in Linguistic Theory*, Bach & Harms, Chicago, Holt, Rinehart and Winston, pp. 1-90, 1968
(2) C. FILLMORE : "Types of Lexical Information" in *Semantics : an Interdisciplinary Reader*, Steinberg & Jakobovits, Cambridge University Press, pp. 370-392, 1971
(3) C. FILLMORE : "Verbs of Judging : an Exercise in Semantic Description" in *Studies in Linguistic Semantics*, C. FILLMORE & LANGENDSEN, Chicago, Holt, Rinehart and Winston, 1971

La notion de "Case-frame" qui correspond au modèle casuel de B. POTTIER[1] permet de traiter correctement certains cas de polysémies et d'homotaxies. Il faut cependant noter des difficultés pour le choix cohérent des cas sémantiques. B. BRUCE[2] a tenté de proposer quelques règles pour définir la notion de cas mais ses indications ne procèdent pas de critères scientifiques indiscutables.
D'autres théories font suite au modèle de C. FILLMORE.

1.4.3.3.2 La théorie de J. GRIMES[3]

Elle a pour but d'atteindre un degré d'abstraction plus élevé en réunissant des cas regroupant des concepts voisins. Un groupe nominal donné peut jouer plusieurs rôles sémantiques distincts, ce qui constitue une différence essentielle avec le modèle de C. FILLMORE. Cette théorie s'applique en fait à l'analyse des discours. Dans le même ordre d'idées, FEUILLET[4] essaie de déterminer un ensemble universel de fonctions sémantiques profondes (*STATIF, AGENTIF, RECEPTIF, OBJECTIF, MEDIATIF, DESCRIPTIF,* et *SITUATIF*), liées à tout ensemble de cas.

1.4.3.3.3 La théorie de R. SIMMONS[5]

Les réseaux sémantiques de R. SIMMONS utilisent également les cas sémantiques profonds (*ACTEUR, THEME, SOURCE, BUT, INSTRUMENT, LIEU, TEMPS*). Le principe de base du mécanisme de l'analyse qu'induit son modèle est de tester la compatibilité des concepts nominaux avec les restrictions correspondant aux cas du verbe.

1.4.3.3.4 La théorie de R. SCHANK

Avec les "Dépendances conceptuelles", R. SCHANK[6] cherche à représenter le sens en s'appuyant sur des relations conceptuelles entre des objets et des actions, ces actions étant indépendantes de la langue. Il définit 11 primitives à partir desquelles pourront être décrites toutes les actions.
La dépendance conceptuelle implique :
- deux phrases ayant une signification équivalente doivent avoir la même représentation interne, même si elles ont des structures syntaxiques très différentes.
- toute information implicite doit être explicite dans la représentation.
- toute action s'exprime en termes de primitives. Chaque primitive possède un schéma associé qui devra être "instancié" et rempli lors du processus de compréhension.

La signification d'une phrase est représentée par un schéma de dépendance conceptuelle. Les catégories qui interviennent dans le schéma sont :

- les PPs (Picture Production) les noms
- les ACTs (Action) les verbes ou groupes de verbes
- les PA (Picture Aider) les modificateurs des PPs comme les adjectifs
- les AA (Action Aider) les modificateurs des ACTs comme les adverbes

---

(1) B. POTTIER : "Vers une sémantique moderne" in *Travaux de Linguistique et de Littérature, Centre de Philosophie et Littérature romanes de Strasbourg*, tome 2, pp. 107-137, Klincksieck, Paris, 1964
(2) B. BRUCE : "Case Systems for Natural Language", *BBN report n°3010*, 1975
(3) J. GRIMES : "The Thread of Discourse", *Rapport technique NSF*, Cornell University, 1972
(4) J. FEUILLET : "Les fonctions sémantiques profondes" in *Bulletin de la Société de Linguistique de Paris*, LXXV, 1, pp. 1-37
(5) R. SIMMONS : "On Managing Sentence Meanings", *Report NL-20*, Dept. of Computer Science, University of Texas, Austin, 1974
(6) R. SCHANK : "Conceptual Dependency : a Theory of Natural Language Understanding", *Cognitive Psychology*, vol.3 (4), pp. 552-631, 1972

Les dépendances peuvent être à double sens (le plus souvent entre un PP et un ACT), à sens unique entre un ACT et un PP ou entre un PP et un PA, à sens unique entre deux PPs.
A la différence d'une représentation en grammaire casuelle, la représentation en DC fait apparaître les relations causales. Représenter la signification d'une phrase consiste à trouver les primitives qui correspondent aux actions et à compléter la structure associée.

Il y a une quinzaine de primitives en tout, parmi lesquelles :

- *ATRANS* : désigne le transfert abstrait de quelque chose à quelqu'un (donner), de quelque chose à soi-même (prendre), le transfert simultané de plusieurs objets (acheter).
- *PTRANS* : désigne le transfert physique de soi-même quelque part (aller), d'un objet quelque part (mettre).
- *SPEAK* indique une production de sons (parler, chanter, siffler).
- *ATTEND* indique le fait de consacrer un organe des sens à un stimulus (écouter, voir).

C. RIESBECK, C. RIEGER et N. GOLDMAN ont développé le programme MARGIE[1] sous la direction de R. SCHANK. Ce programme analyse des phrases en langue naturelle pour les transformer en une représentation de dépendance conceptuelle. On trouve des applications des théories de R. SCHANK en T.A. et T.A.O. avec les systèmes HICATS (2.3.3.2.2) pour l'analyse sémantique et ATLAS II (2.3.3.2.1) avec les réseaux sémantiques.

Les travaux de Y. WILKS[2] sont assez voisins, avec la théorie des sémantiques préférentielles.

1.4.3.3.5 Le modèle de B.B. BOGURAEV et K. SPARK-JONES[3]

A partir d'un grand corpus et avec le souci de déterminer un ensemble de cas exhaustif, B.B. BOGURAEV et K. SPARK-JONES s'appuient sur les travaux de F.T. WOOD[4] et proposent une liste de 27 cas.

D. RUMELHART, P. LINDSAY et D. NORMAN[5] ont construit le modèle de mémoire dans lequel la connaissance est codée comme un ensemble de propositions et de concepts liés par des cas sémantiques (notions de réseau sémantique et de schéma).

Parmi les applications informatiques de ce type de grammaire figurent :

- les recherches de B. NASH-WEBBER[6], qui utilisent les cas sémantiques pour s'assurer que les structures syntaxiques repérées ont bien un sens (projet SPEECHLIS).

---

(1) R.C. SCHANK : *Conceptual Information Processing*, New York, 1975, North Holland
(2) Y. WILKS : "A Preferential Pattern-seeking Semantics for Natural Language Inference", *Artificial Intelligence*, 6, pp. 53-74, 1975
(3) B.B. BOGURAEV, K. SPARK-JONES : "How Drive a Database Front-end Using General Semantic Information", *Conference on Applied Natural Language Processing*, Santa Monica, pp. 81-88, 1983
(4) F.T. WOOD : *English Prepositional Idioms*, MacMillan, 1979, Londres
(5) D. RUMELHART, P. LINDSAY, D. NORMAN : "A Process Model of Long Term Memory" in *Organization of Memory*, Tulving & Donalson, Academic Press, 1975, Ney York
(6) B. NASH-WEBBER : "Semantic support for a spech understanding system", in *Representation and understanding, studies in cognitive science*, Bobrow & Collins, Academic Press, 1975, New York

- Le programme CHRONOS de G. BROWN, B. BRUCE et M. TRIGOBOFF[1], qui analyse le langage en traitant des ensembles de cas adaptés au domaine abordé.

Le premier avantage des grammaires de cas est la représentation sémantique que l'on obtient, la notion de verbe et de son modèle casuel rappelant l'application du prédicat logique à des arguments.

Le second avantage est la possibilité, tout en utilisant les contraintes syntaxiques, de se diriger vers une analyse purement sémantique reposant sur les restrictions de sélection apportées par les modèles casuels.

La possibilité de traiter des phrases à syntaxe incorrecte justifie l'emploi du modèle pour le traitement automatique, en particulier pour les systèmes question-réponse destinés au grand public. De nombreux aspects ne peuvent être abordés, les phrases non verbales par exemple.

1.4.3.4. Les grammaires sémantiques

Il est parfois difficile de conduire une analyse syntaxique complète avant tout début d'interprétation. De même, la jonction des niveaux syntaxique et sémantique au cours d'une analyse peut-être laborieuse. R.R. BURTON[2] propose d'étendre les règles d'analyse des grammaires indépendantes du contexte en classant les mots non plus seulement d'après leur nature grammaticale mais aussi d'après leur signification. A. BONNET[3] multiplie par 5 la vitesse d'interprétation de comptes-rendus médicaux, en introduisant les classes d'information qui, à l'inverse des cas, sont spécifiques de l'application. Le champ de l'application doit être limité (cas des dialogues dans les systèmes experts). Pour la résolution des ellipses, A. BONNET suggère de reprendre les dernières dérivations jusqu'à celle qui permettra de compléter les données manquantes. Ces grammaires permettent de traiter des énoncés normés. Très faciles à mettre en œuvre dans des domaines restreints, elles sont très souples mais aboutissent à une compréhension assez limitée.

1.4.3.5 Les grammaires systémiques

1.4.3.5.1 Présentation

Elles ne considèrent plus le langage comme un système isolé mais comme une activité sociale.
B. MALINOWSKI[4] puis B. WHORF[5] focalisent leurs travaux sur les aspects fonctionnels du langage et le rôle des différents constituants par rapport aux intentions du discours.

---

(1) G. BROWN, B. BRUCE, M. TRIGOBOFF : "The CHRONOS Natural Language Understanding System", Computer Science Department, Rutgers, *NIH report CBM-tr-30*, 1974
(2) R.R. BURTON : "Semantic Grammars, an Engineering Technique for Constructing Natural Language Understanding Systems", *Rapport BBN n°3453*, Dec. 1976
(3) A. BONNET : "Les grammaires sémantiques, outil puissant pour interroger les bases de données en langage naturel", *Rairo informatique*, 14(2), pp. 137-148, 1980
(4) B. MALINOWSKI : "Culture" in *International Encyclopedie of the Social Sciences*, Sills, New York, MacMillan, 1968
(5) B. WHORF : *Language, Thought and Reality*, Caroll, Cambridge Mass., MIT Press.

J.R. FIRTH[1] introduit ces idées dans la linguistique avec les premières notions de système. M. HALLIDAY[2] élabore une théorie complète, concentrée sur l'organisation fonctionnelle du langage et les rapports entre la forme du texte et le contexte dans lequel il est produit.
L'avantage de ce modèle descriptif réside, pour l'Intelligence Artificielle, dans l'approche de la sémantique et de la pragmatique, essentielle pour la gestion des dialogues homme-machine. Il est en effet très simple, en informatique, de tranférer des traits d'une procédure à une autre, ce qui permet de tenir compte des contextes et de prendre des décisions fondées sur l'interaction de plusieurs processus.

1.4.3.5.2 Notion de système

Les fonctions envisagées selon divers points de vue peuvent se recouvrir, il est possible également qu'un même constituant puisse jouer plusieurs rôles.

Un mot, un groupe de mots peut représenter le sujet, l'objet, l'agent... Les grammairiens systémiques partent du principe que la combinaison de ces fonctions n'est pas due au hasard, qu'elles appartiennent en fait à différents systèmes qui agissent ensemble pour déterminer la structure et le rôle de la phrase.

La description des systèmes utilise un formalisme simple. Dans le cas d'un choix simple, le schéma est le suivant :

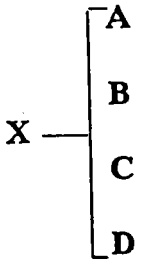

Si un élément a la caractéristique X, il a un des traits A,B,Cou D, (exclusifs les uns des autres).

La représentation peut être récursive. Si une catégorie est retenue, d'autres choix peuvent intervenir, uniquement dans ce cas. On peut, dans le schéma suivant, avoir le choix entre E et F, pour les objets qui ont le trait B, seulement.

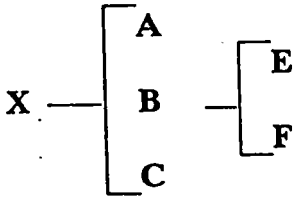

On peut également effectuer plusieurs choix indépendants les uns des autres (orthogonaux), ou encore, des choix non marqués.

---

(1) J.R. FIRTH : "A synopsis of Linguistic Theory (1930-1955)" in *Selected papers of* J.R. FIRTH, Palmer, Longman, Londres, pp. 168-205, 1957
(2) M. HALLIDAY : *Categories of the Theories of Grammar Word*, 17, pp. 241-292, 1961

1.4.3.5.3 Le modèle de M. HALLIDAY

M. HALLIDAY distingue 4 systèmes qui agissent séparément dans la détermination de la structure de la phrase (*MODE, ACTANTS, THEMATIQUE et INFORMATIF*).

- Le système du mode précise le type d'énonciation de la phrase (question, réponse, ordre...). Ces catégories sont définies a priori, mais, dans la pratique, ramènent aux catégories syntaxiques. Ce système fournit également des indications sur les rôles des constituants pour opérer les choix.
- Le système d'actants détermine les divers participants et les relations qu'ils entretiennent, syntaxiques ou, plus souvent, sémantiques. Le mécanisme est proche de celui des grammaires casuelles et appelle par conséquent les mêmes critiques.
- Le système thématique s'appuie sur le fait qu'une phrase met en évidence l'élément dont on parle (le thème), le reste de la phrase représente une propriété ou un prédicat qu'on lui attribue (le rhème). Le système thématique précise la structure prédicative de la phrase. Il est à quelques exceptions près, indépendant du système d'actants, mais très lié au système de mode.
- Le système informatif souligne ce qui représente une information nouvelle par rapport à ce que l'interlocuteur sait déjà.

1.4.3.5.4 T. WINOGRAD et le SHRDLU

Ce programme reste le plus célèbre dans l'histoire de l'Intelligence Artificielle. Il a été développé au M.I.T. par T. WINOGRAD[1] et simule un robot qui peut manipuler divers objets disposés sur une table, en conversant en langue naturelle avec un interlocuteur qui lui donne des ordres ou lui pose des questions sur les objets.
La grammaire utilisée est dérivée des grammaires systémiques de M. HALLIDAY. Un système de réseaux spécifie certaines propriétés des unités syntaxiques comme le mode, le temps et la voix pour les verbes. En cours d'analyse, des informations sémantiques réduisent le nombre de structures potentielles selon des critères purement syntaxiques.
Le module syntaxique, pour représenter le sens de la phrase, construit un arbre syntagmatique aux nœuds duquel sont attachés des traits issus d'une grammaire systémique. Cette méthode est parfois nommée technique des arbres décorés.
Les grammaires systémiques sont essentiellement explicatives et descriptives. Elles peuvent cependant engendrer des phrases si l'on associe à chaque trait un ensemble de règles de réalisation qui se résument à cinq types (*INCLUSION, CONFLATION, GATEGORISATION, ACCORD, ORDONNANCEMENT*). Ces grammaires sont très intéressantes lorsque l'on envisage l'intégration d'aspects syntaxiques et sémantiques.
Les systèmes ENGSPAN et SPANAM (2.3.3.3.6) s'inspirent des grammaires systémiques.

1.4.3.6 Grammaires et lexique

1.4.3.6.1 Les grammaires d'unification

Nous avons noté qu'en grammaire générative, le module d'insertion lexicale intervenait avant l'application des règles syntaxiques et constituait une étape délicate. Les grammaires d'unification et les grammaires lexicales fonctionnelles appliquent une analyse fondée sur les caractéristiques syntaxiques et sémantiques des mots de la phrase.

---

(1) T. WINOGRAD : Understanding Natural Language, New york, Academic Press, 1972

Les modèles obtenus sont plus riches et plus souples que celui de N. CHOMSKY. Leur originalité est de considérer de façon uniforme les informations des dictionnaires, les connaissances sur la structure et les règles grammaticales comme des conditions nécessaires pour qu'un élément donné ait une forme correcte.

M. KAY[1] tente de construire un formalisme unique pour traiter ces aspects et introduit les "descriptions fonctionnelles". J. BRESNAN et R. KAPLAN[2] ont développé la notion de description additive, permettant des descriptions partielles complémentaires. Leur grammaire lexicale fonctionnelle accorde un rôle essentiel au lexique et aboutit à la description interne d'une phrase articulée en structure de constituants (aspects syntaxiques) et en structure fonctionnelle (aspects sémantiques).

1.4.3.6.1.1 Le formalisme

Il doit être le même pour représenter les données lexicales, les règles de grammaire et les structures internes des phrases. On utilise le modèle de schéma proposé à l'origine par M. MINSKY[3].

- un constituant se décrit par un ensemble de couples (chaque couple en donne une description partielle, indépendante des autres).

{(Attribut = Valeur)}

La notation est toujours identique, que l'attribut soit une fonction, la description d'un trait ou une unité lexicale.

- Les schémas (*Frames*) sont présentés dans des "boîtes", symbolisées par des crochets "[ ]", qui peuvent s'emboîter pour traduire la structure à la manière d'un parenthésage. On les réunit par une accolade chaque fois que plusieurs solutions sont possibles à un niveau donné.

- Un attribut est obligatoire, c'est la catégorie. Les réalisations lexicales ont l'attribut LEX. Sa valeur est le mot étudié.

Les autres types de schéma contiennent l'attribut FORME qui, à l'aide de descriptions partielles, indique les contraintes sur l'ordre des constituants concernés.

1.4.3.6.1.2. Utilisation du formalisme

Nous allons présenter des exemples pour chacune des trois applications. Une partie de ces exemples sont empruntés à G. SABAH[4]

---

(1) M. KAY : "Functional Grammars", *Actes 5th Annual Meeting of the Berkeley Linguistic Society*, pp. 142-158, 1979

(2) J. BRESNAN, R. KAPLAN : "Lexical Functional Grammars ; A Formal System for Grammatical Representation", in *The Mental Representation of Grammatical Relations*, J. BRESNAN (ed.), MIT press, Cambridge Mass., 1981

(3) M. MINSKY : "A Framework for Representing Knowledge", *Memo 308*, MIT, Cambridge Mass., 1974

(4) G. SABAH : *L'intelligence artificielle et le le langage*, Vol. 1, représentations des connaissances, pp. 128-155, 1988

- exemple de formalisme appliqué au lexique : une description dans le dictionnaire du nom masculin, singulier, *canari* aurait la forme :

Catégorie	=	Nom
Nombre	=	Singulier
Genre	=	Masculin
Lex	=	*canari*

Si le dictionnaire contient les formes fléchies, on trouvera pour *achètera* :

Catégorie	=	Verbe
Temps	=	Futur
Type	=	Action
Racine	=	*acheter*
Lex	=	*achètera*

Dans le cas d'un terme ambigu comme *la* (article défini, pronom personnel, note de musique), on regroupe les trois possibilités :

Catégorie	=	Article
Type	=	Défini
Nombre	=	Singulier
Genre	=	Féminin
Lex	=	*la*

Catégorie	=	Pronom
Type	=	Personnel
Nombre	=	Singulier
Personne	=	Troisième
Genre	=	Féminin
Lex	=	*la*

Catégorie	=	Nom
Nombre	=	Singulier
Genre	=	Masculin
Lex	=	*la*

- exemple de formalisme appliqué aux règles grammaticales. Soit une grammaire ne permettant que les deux types de phrase suivants :

GN + GV + GN
GN + GN + GV

Les **GN** sont des pronoms ou des chaînes composées d'un déterminant, d'un nombre quelconque d'adjectifs, d'un nom suivi à nouveau d'un nombre quelconque d'adjectifs.

Le **GV** est formé d'un verbe seul.

En indiquant par * que l'élément suivant est facultatif ou répété un nombre quelconque de fois, la description fonctionnelle correspondant à la grammaire ci-dessus aura la forme :

```
[ [ Catégorie  =        Phrase
  [ Forme      =        (GN GV GN)
    [ [ Cat      =      GN
      [ Forme    =      (DET*ADJ NOM*ADJ)
      [ DET      =      [ Cat = DET ]
      [ NOM      =      [ Cat = NOM ]
      [ ADJ      =      [ Cat = ADJ ]
      [ Cat      =      GN
      [ Forme    =      (PRON)
      [ PRON     =      [ Cat = PRON ]
    [ Cat      =        VERBE
    [ Forme    =        (VERBE)
    [ VERBE    =        [ Cat = VERBE ]
  [ Catégorie  =        Phrase
  [ Forme      =        (GN GN GV)
```

- exemple de formalisme appliqué à la représentation interne d'une phrase :
La représentation de la structure de la phrase qui permettra d'appréhender son sens est construite à partir des règles de grammaire et des représentations lexicales.

Représentons le groupe nominal *le poisson* :

Cat	=	GN		
Forme	=	(DET NOM)		
DET	=	Cat	=	Article
		Type	=	Défini
		Nombre	=	Sing.
		Genre	=	Masculin
		Lex	=	*le*
NOM	=	Cat	=	NOM
		Nombre	=	Sing.
		Genre	=	Masculin
		Lex	=	*poisson*

On note que la catégorie syntaxique est GN et qu'il est constitué d'un déterminant et d'un nom. Des schémas en précisent les différents traits avec la lexicalisation correspondante (LEX).

1.4.3.6.1.3 La superposition

Lors de la construction de la représentation interne, on est parfois amené à utiliser la notion de superposition pour construire une description fonctionnelle à partir de deux autres descriptions fonctionnelles, à condition que des attributs identiques n'aient pas de valeurs incompatibles

Catégorie	=	Nom
Nombre	=	Singulier
Lex	=	poisson

+

Catégorie	=	Nom
Genre	=	Masculin
Personne	=	3ème

→

Catégorie	=	Nom
Nombre	=	Singulier
Genre	=	Masculin
Personne	=	3ème
Lex	=	poisson

S'il permet de compléter une description à partir de descriptions partielles (dans l'exemple, descriptions du concept *poisson* et de la catégorie lexicale nom masculin), le mécanisme de superposition permet de résoudre des ambiguïtés lexicales.

On parvient ainsi à la description d'un langage qui permet d'expliciter les règles de grammaire, de représenter les éléments du dictionnaire et les structures internes de la phrase, ce qu'il est possible d'assimiler à une grammaire indépendante du contexte.

Un exemple de résolution d'une ambiguïté par superposition serait :

Catégorie	=	Article
Type	=	Défini
Nombre	=	Singulier
Genre	=	Féminin
Lex	=	*la*

Catégorie	=	Pronom
Type	=	Personnel
Nombre	=	Singulier
Personne	=	3ème
Genre	=	Féminin
Lex	=	*la*

Catégorie	=	Nom
Nombre	=	Singulier
Genre	=	Masculin
Lex	=	*la*

superposé à :

Catégorie	=	Pronom
Nombre	=	Singulier

donnera la seule solution :

Catégorie	=	Pronom
Type	=	Personnel
Nombre	=	Singulier
Personne	=	3ème
Genre	=	Féminin
Lex	=	*la*

1.4.3.6.1.4 La notion de chemin

La notion de chemin qui traduit des références aux divers éléments d'une structure décrite par ce langage, détermine des contraintes qui augmentent la puissance du modèle. On décrit un chemin dans une description fonctionnelle DF1 par la notation <a_1, a_2, ... a_n>.

exemple : test d'accord, en genre et en nombre, dans le groupe nominal, du déterminant et des adjectifs avec le nom.

GN =

Cat	=	GN
Forme	=	(DET*ADJ NOM*ADJ)
DET	=	[Cat = DET]
NOM	=	[Cat = NOM]
ADJ	=	[Cat = ADJ]
EGAL	=	<DET, GENRE>, <NOM, GENRE>
EGAL	=	<ADJ, GENRE>, <NOM, GENRE>
EGAL	=	<DET, NOMBRE>, <NOM, NOMBRE>
EGAL	=	<ADJ, NOMBRE>, <NOM, NOMBRE>

Les attributs GENRE et NOMBRE ne figurent pas pour DET, NOM et ADJ. Le mécanisme de superposition, appliqué à cette règle et à la description lexicale, les feront apparaître.
L'avantage de ce formalisme tient à l'unité dans les descriptions et à la facilité d'intégration des différents types de connaissances.

1.4.3.6.2 Les grammaires lexicales fonctionnelles

Développées par J. BRESNAN et R. KAPLAN[1], ces grammaires privilégient les lexiques et donnent des descriptions partielles qui, grâce à la notion de description additive, peuvent ensuite se compléter.

La structure de constituants ou *C-structure* (aspects syntaxiques) et la structure fonctionnelle ou *F-structure* (aspects sémantiques) contribuent à la description interne d'une phrase.

La C-structure est le résultat d'une analyse de la phrase par une grammaire indépendante du contexte. Cette dernière autorise des structures incorrectes qui seront éliminées par la F-structure.

La F-structure s'appuie sur la notion de schéma telle que nous venons de l'introduire, débarrassée de la notion de *forme*, désormais inutile puisque les aspects syntaxiques sont traités par la C-structure. Associées aux règles de la grammaire, des équations génèrent la structure fonctionnelle. Elles sont écrites selon la notation LISP.

(A,B) représente "l'attribut B de l'élément A".

Ces équations doivent être considérées comme liées aux arcs de l'arbre engendré.

↑ désigne la F-structure du nœud père
↓ désigne la F-structure du nœud fils

L'équation (↑ **Nombre**) = **singulier** attachée à l'article *un* dans le lexique, signifiera que le nombre de la F-structure du déterminant est singulier, (cet élément sera en effet lié à un nœud de type déterminant après l'étape d'insertion lexicale).

De même, pour la règle :

P ⟶ **GN GV**

on a les deux équations :

(↑ Sujet) = ↓ et ↑ = ↓

↑ désigne "P", ↓ successivement GN et GV.
Cette règle précise que les constituants de la phrase sont un GN et un GV.

(↑ Sujet) =↓ Cette première équation indique que le sujet de la F-structure de la phrase est identique à la F-structure du 1er groupe nominal.

↑ = ↓ Les structures de P et de GV sont égales.

En matière d'entrée lexicale, pour *un* et *donne*, par exemple, on peut trouver la description suivante :

---

(1) **J. BRESNAN, R. KAPLAN : "Lexical Functional Grammars ; A Formal System for Grammatical Representation" in *The Mental Representation of Grammatical Relations*, J. BRESNAN (ed.), MIT press, 1981, Cambridge Mass.**

un	Déterminant	(↑Définition) = indéfini (↑Nombre) = singulier
donne	Verbe	(↑Temps) = présent (↑Prédicat) = donner < (↑S), (↑O), (↑O2) >

La structure du prédicat comprend 3 actants, le sujet et les deux objets du verbe. On note ainsi au niveau du lexique les formes que prendra une représentation logique dans laquelle interviendra le mot.

Le même formalisme permet de décrire les règles de grammaire qui entreront par la suite dans le calcul de la C-structure et la résolution des équations menant à la F-structure.

Règle 1 :

Deux équations sont associées à la règle :

P-->GN+GV	La phrase est formée d'un groupe nominal et d'un groupe verbal.

Règle 2 :

(↑sujet) =↓	Le sujet de la F-structure et le GN ont la même structure.
↑= ↓	P et GV ont la même structure

Règle 3 :

GN ——→ Déterminant Nom C-structure de GN

Trois équations sont associées à la règle :

GV ——→ Verbe GN GP C-structure de GV

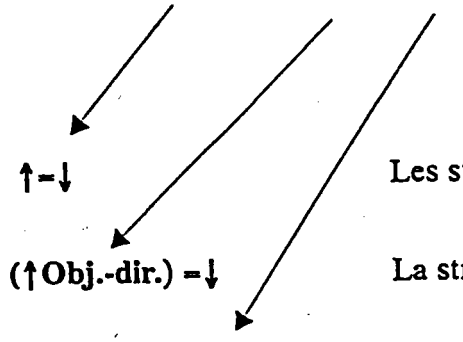

↑=↓	Les structures du GV et du verbe sont identiques.
(↑Obj.-dir.) =↓	La structure du 1er GN est celle de l'objet direct du GV.
(↑Obj.-ind.) =↓	La structure du 2ème GN est celle de l'objet indirect du GV.

1.4.3.6.2.1 La production d'une phrase

Elle s'effectue en trois étapes :
- 1ère étape : La grammaire indépendante du contexte, sans que l'on tienne compte des équations liées aux règles, produit un arbre de dérivation dont toutes les feuilles sont des catégories lexicales.
- 2ème étape : C'est l'insertion lexicale avec l'attribution à chaque feuille d'un mot approprié du dictionnaire. On actualise ensuite les équations en substituant aux flèches les variables qui conviennent.
- 3ème étape : Les équations sont résolues et donnent la structure fonctionnelle de la phrase.

1.4.3.6.2.2 La représentation d'une phrase

Elle repose ainsi sur deux éléments : la C-structure et le F-structure.
La C-structure donne une représentation syntaxique de la phrase, on y distingue deux types de nœuds :
- les catégories syntaxiques (P, GN, GV, GP, ...) auxquelles sont associées les variables notées xj (1 variable par nœud).
- les nœuds lexicaux (art., nom, prép., verbe, ...) placés juste au dessus des nœuds terminaux (les mots).

A partir de cette structure, des règles de grammaire et des règles associées au lexique, on déduit des équations qui permettront de construire la structure fonctionnelle :

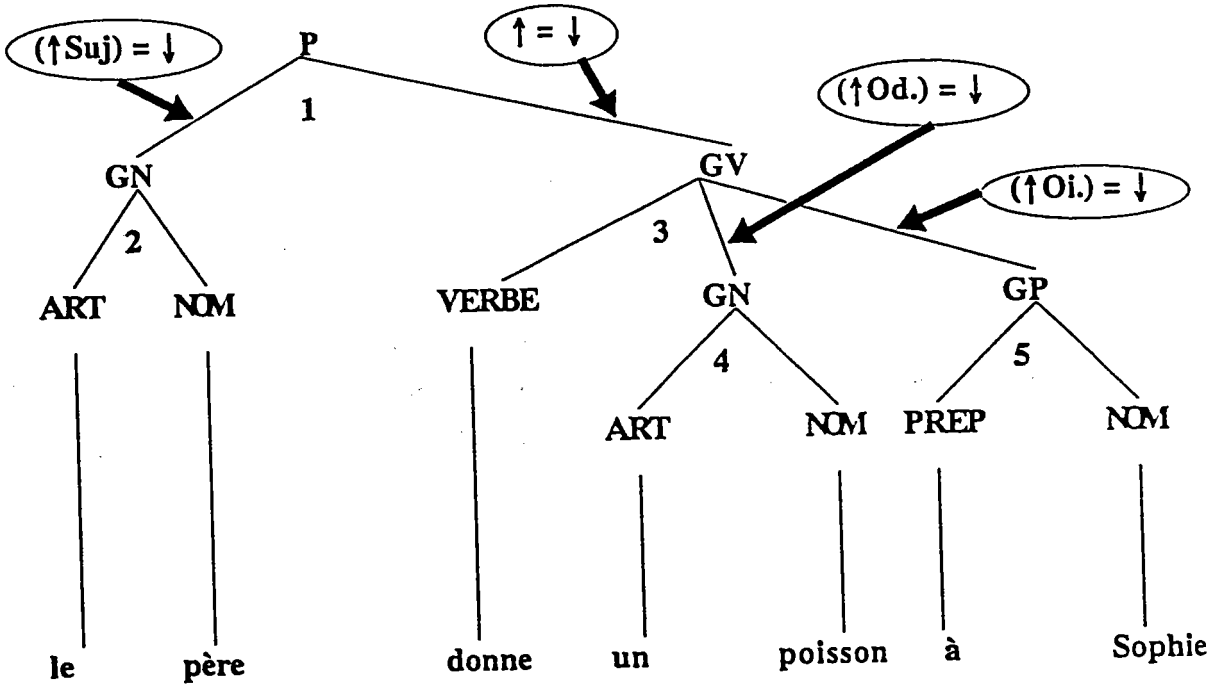

P est sur le nœud x_1
GN et GV sont sur les nœuds x_2 et x_3
GN et GP sont sur les nœuds x_4 et x_5

Règle de grammaire : P ⟶ GN GV

En remplaçant les flèches dans les équations correspondantes, on obtient :
(↑sujet) = ↓ ⟶ $x_1$sujet = x_2
↑ = ↓ ⟶ $x_1 = x_3$

de même, pour GV :

$(\uparrow \text{Obj.-dir.}) = \downarrow \longrightarrow (x_3\text{Obj.-dir.}) = x_4$
$(\uparrow \text{Obj.-ind.}) = \downarrow \longrightarrow (x_3\text{Obj.-ind.}) = x_5$

Règles du lexique :

le Déterminant $(\uparrow \text{Définition}) = \text{défini} \longrightarrow (x_2\text{Définition}) = \text{défini}$
$(\uparrow \text{Nombre}) = \text{singulier} \longrightarrow (x_2\text{Nombre}) = \text{singulier}$

père $\longrightarrow (x_2\text{Concept}) = \text{père}$
$\longrightarrow (x_2\text{Nombre}) = \text{singulier})\ldots$

Les équations résolues, on obtient la structure fonctionnelle (représentation sémantique) suivante :

$x1 = x3 =$
[Sujet = x2
Obj.-dir. = x4
Obj.-ind. = x5
Temps = présent
Concept = *donner* <père, poisson, Sophie>]

$x2 =$
[Définition = défini
Nombre = singulier
Concept = *père*]

$x4 =$
[Définition = indéfini
Nombre = singulier
Concept = *poisson*]

$x5 =$
[Définition = défini
Concept = *Sophie*]

2.5.3.6.2.3 Phénomènes à distance, éléments discontinus

Les symboles $\Uparrow X$ et $\Downarrow X$ (X est une catégorie grammaticale) représentent successivement la F-structure de l'élément contrôlé et celle du contrôleur. A chaque $\Uparrow X$ correspondra un $\Downarrow X$.
$\uparrow = \Uparrow X$ et $\downarrow = \Downarrow X$ signifient que les deux F-structures doivent se correspondre. Pour traiter des liaisons à distance comme dans la phrase *Combien de poissons le père donne-t-il à Sophie ?* on ajoute deux règles :
1. P $\longrightarrow$ GN GN GV avec les équations $\downarrow = \Downarrow X$, $(\uparrow \text{sujet}) = \downarrow$ et $\uparrow = \downarrow$
2. GN $\longrightarrow \varnothing$ avec l'équation $\uparrow = \Uparrow GN$
La règle 2 indique que n'importe quel GN peut se réécrire en un élément nul. Une C-structure pourra du reste contenir un nombre quelconque de tels GN puisque la grammaire est indépendante du contexte.

Les symboles ⇑ et ⇓ fonctionnant par paire, l'analyse se soldera par un échec s'il y a un déséquilibre car les équations associées aux règles ne pourront être résolues.

La C-structure sera :

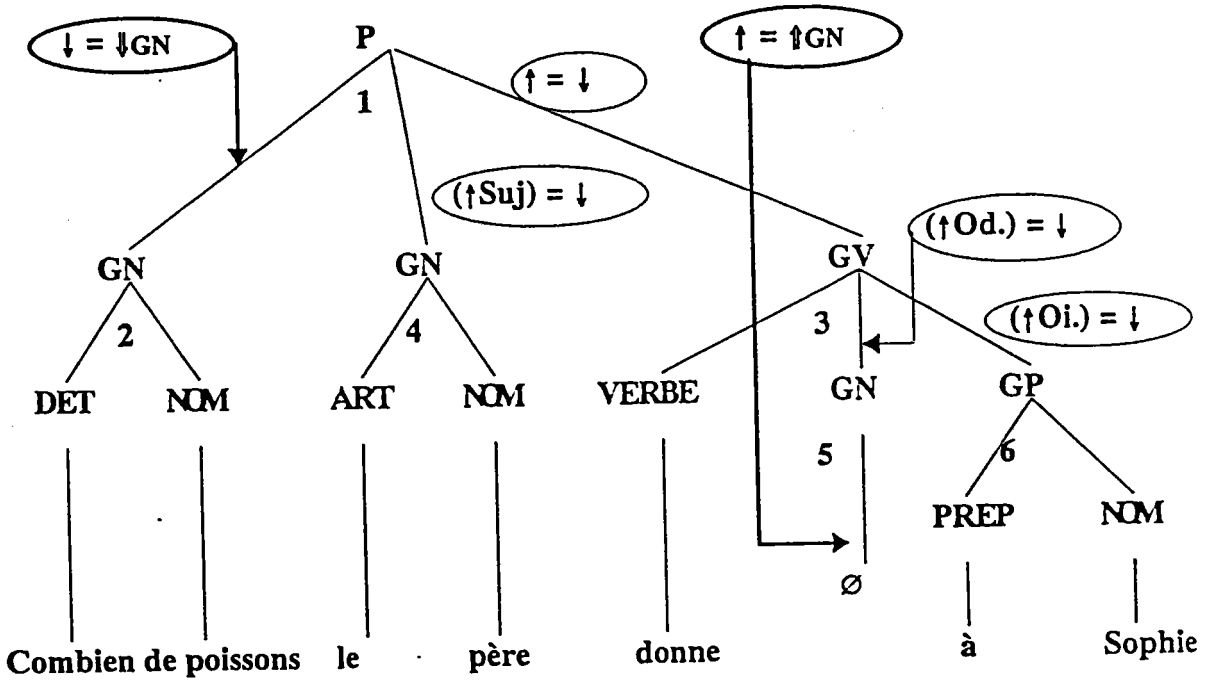

La structure fonctionnelle correspondante :

x1 = x3 =

Forme	= question
Sujet	= x4
Obj.-dir.	= x5
Obj.-ind.	= x6
Temps	= présent
Concept	= *donner* <père, poisson, Sophie>

x4 =

Définition	= défini
Nombre	= singulier
Concept	= *père*

x2 = x5 =

Définition	= indéfini
Nombre	= singulier
Concept	= *poisson*

x6 =

Définition	= défini
Concept	= *Sophie*

La dépendance à distance est exprimée dans la F-structure par l'égalité x2 = x5
Un mécanisme identique permet de représenter des constituants discontinus comme dans la phrase *Combien le père donne de livres à Sophie ?* en ajoutant les règles :

1. GN ⟶ DET NOM avec l'équation ↓ = ⇓NOM
2. GN ⟶ ∅ avec l'équation ↑ = ⇑NOM

On obtient le schéma :

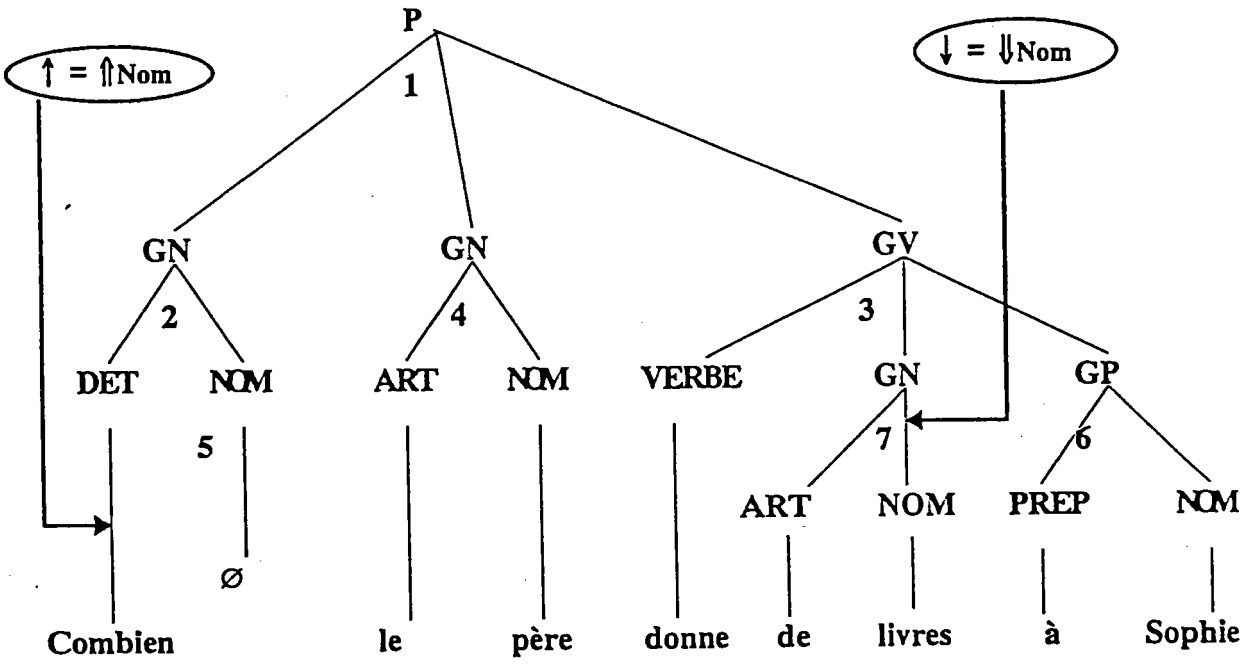

1.4.3.6.3 Le lexique-grammaire de M. Gross

En partant comme Z. HARRIS d'un modèle de la langue le moins formalisé possible, M. GROSS dresse un inventaire systématique des diverses constructions syntaxiques du français.

1.4.3.6.3.1 Les dictionnaires du LADL (Laboratoire Documentaire et Linguistique)

DELAS est un dictionnaire de 50 000 mots dans lequel sont stockés les formes canoniques et des codes indiquant les types de flexion des mots, indépendamment des sens possibles.
DELAF réunit les 350 000 formes fléchées associées, générées automatiquement à partir de DELAS.
DELAP donne une représentation phonétique à chaque entrée de DELAS.

Des analyseurs, des générateurs, des programmes de "syllabation" et de classement ainsi que différents outils logiciels sont utilisés pour la construction de programmes de correction orthographique.

Il faut également mentionner le recensement des expressions complexes, de locutions courantes et de noms composés.

1.4.3.6.3.2 Les lexiques-grammaires

Le traitement automatique du langage naturel nécessite une représentation systématique des langues naturelles, utilisable par des automates. Traditionnellement le lexique, la grammaire et la sémantique sont couverts par les dictionnaires et les grammaires classiques. En situation d'apprentissage, les êtres humains s'accommodent d'une part d'implicite. Les ordinateurs, par contre, ont besoin de descriptions exhaustives, répertoriées et formalisées pour une application informatique comme la traduction automatique. Les dictionnaires évoqués précédemment tiennent surtout compte des données morphologiques.

Les aspects syntaxiques élémentaires (relations du verbe avec d'autres catégories lexicales par ex.) sont abordés au cours d'autres travaux qui consistent à décrire systématiquement un mot (selon son sens, pour tenir compte de l'influence du sens sur la syntaxe) par rapport à environ 500 propriétés syntaxiques.

M. GROSS a entrepris d'élaborer un dictionnaire électronique des verbes du français (lexique-grammaire), qu'il conçoit comme une grande base structurée de données lexicales, associant à la description de chaque entrée les règles syntaxiques d'emplois, sous forme de schémas d'insertion de l'item verbal. Achevé pour 12 000 verbes, le dictionnaire morphosyntaxique du Laboratoire Documentaire et Linguistique (LADL) présente plusieurs milliers de schémas descriptifs.

On constate ensuite que ces propriétés syntaxiques utilisées comme critères de classement, mettent en évidence, pour les verbes étudiés, le fait que les verbes sémantiquement apparentés ont souvent des propriétés syntaxiques communes.

1.4.3.6.4 Le modèle Sens-Texte de I. MEL'CUK[1]

Le modèle de I. MEL'CUK et de A.K. ZOLKOVSKIJ appartient aux modèles informatiques du langage. Il est organisé comme un processus qui mettrait en correspondance une représentation du sens (représentation sémantique) avec un texte (énoncé écrit ou oral).

Il a pour but

- d'expliquer une même idée de plusieurs façons
- d'identifier diverses expressions d'apparence différentes mais ayant le même sens.

Le sens n'est ni l'interprétation des expressions décrites par la syntaxe (modèles de N. CHOMSKY et modèles de sémantique formelle), ni étudié indépendamment du texte. Le sens est défini comme "l'invariant des transformations synonymiques (les paraphrases)".

Loin des modèles de N. CHOMSKY dont les structures profondes sont essentiellement des représentations syntaxiques, le modèle est hiérarchisé en 7 niveaux. Ses structures lexico-syntaxiques de base sont en effet des structures qui représentent le sens.

---

(1) I. MEL'CUK, A.K. ZOLKOVSKI : *Vers un modèle "Sens-Texte" du langage*, Documents de Linguistique Quantitative, n°10, Paris, Dunod, 1971

Des phrases en relation paraphrastique ont une même représentation sémantique sous forme d'une même SLSB mais se distinguent par les SLS différentes. Les FS regroupent des phrases synonymes dont les SLSB sont toutefois distinctes (à cause des variations lexicales).

L'ensemble de ces modèles et de ces théories peut sembler disparate. Le manque d'unité n'est qu'apparent. Après avoir ilustré des points de vue essentiellement syntaxiques et formels (grammaires formelles, grammaires transformationnelles, théorie standard, théorie standard étendue, théorie des traces, grammaire en chaîne), nous avons parcouru les techniques plus récentes, orientées vers les aspects sémantiques (grammaire syntagmatique généralisée, grammaire de cas, grammaire lexicale fonctionnelle), les aspects fonctionnels (grammaire systémique, grammaire fonctionnelle) et le rôle du lexique (théorie de M. GROSS et modèle "Sens-Texte" de I. MEL'CUK).

1.4.4 Conclusion

La possibilité d'écrire et d'utiliser conjointement les connaissances lexicales, syntaxiques, sémantiques et même pragmatiques confère un grand avantage aux grammaires d'unification. Issues des grammaires transformationnelles, elles s'en démarquent pourtant nettement, avec le rôle qu'elles accordent à la fonction grammaticale, à la structure et au lexique qui est fondamental. Les grammaires fonctionnelles introduisent des notions de variable qui les disposent au traitement automatique. Elles fournissent l'appareil théorique nécessaire à la TAO. Examinons maintenant les outils informatiques.

1.5 Les outils

1.5.1 Introduction

Nous observerons ici les aspects opératoires, autrement dit, les techniques informatiques qui vont utiliser les connaissances représentées selon les modèles que nous avons parcourus dans le paragraphe 1.4. Nous présenterons les modules classiques d'analyse morphologique, syntaxique et morphosyntaxique, puis les analyseurs déterministes, les analyseurs dirigés par le lexique, les outils logiques dans le sens où ils ont un usage spécifiquement lié au langage naturel, les outils intégrés. Nous conclurons sur le traitement des différentes erreurs.

Nous laissons de côté les techniques mises en oeuvre pour expliciter les relations entre les phrases (les inférences, les références et les grammaires de récit). Elles appartiennent au traitement automatique des langues mais contrairement aux modèles linguistiques évoqués plus haut, concernent des applications précises, distinctes de la Traduction Automatique. Nous ne nous intéresserons pas non plus aux mécanismes de génération, puisque l'objet de notre travail se limite à l'analyse.

1.5.2 L'analyse morphologique

On peut distinguer plusieurs types d'analyse selon le but poursuivi. Il s'agit en général de reconnaître les mots sous leurs différentes formes, en distinguant la *forme canonique* (une entrée du dictionnaire par exemple) et les *formes fléchies* (selon le rôle qui leur est assigné dans la phrase et les marques qui leur sont attribuées, comme celles du genre, du nombre ...). Cela permet d'effectuer des recherches ultérieures dans les dictionnaires de formes canoniques.

Pour analyser correctement une forme fléchie, il est indispensable de pouvoir la décomposer en repérant la racine, les affixes et les désinences. Des problèmes supplémentaires interviennent lorsque le mot est composé, comme nous le verrons pour l'al-

lemand (3.3.3.2 et 4.3.2.5). Le problème des irrégularités renvoie à la structure complexe du mot, qui ne peut souvent être appréhendée sans un recours à l'étymologie, aux phénomènes d'emprunt et aux mécanismes de formation que sont la composition et la dérivation. Isoler les racines et maîtriser les affixes (préfixes, suffixes) impliquent que l'on organise ces données en systèmes, selon les buts poursuivis.

La construction de tels systèmes et la gestion des influences des bases[1] et des affixes sur le sens, évitent la construction de dictionnaires qui ne sont jamais exhaustifs, et facilitent la compréhension des mots nouveaux ou inconnus. C'est un des principes que nous avons retenus pour notre système et qui sera développé dans 3.2. Le traitement d'une langue flexionnelle comme l'allemand permet de mesurer les avantages d'une telle démarche. Nous verrons à ce propos qu'il est souvent difficile d'identifier clairement le sens d'un préfixe ou d'un suffixe et qu'il est plus intéressant de raisonner sur une base. Le traitement des composés se heurte au problème de leur sens qui n'est pas toujours égal à la juxtaposition des sens de chaque terme. Dans le même ordre d'idée, le sens de certaines expressions n'est pas forcément déductible des sens des mots qui les composent. Ces expressions figées ou semi-figées sont, de plus, aussi fréquentes que les expressions non spécifiques[2,3]. Il est indispensable de les localiser dès l'étape de l'analyse morphologique, ce qui ne pourra se faire qu'à partir d'une base de recensement.

1.5.2.1 Les techniques

Il y a deux types de dictionnaires.

1 - *Le dictionnaire de formes canoniques* qui nécessite un module d'analyse et un module de génération, pour retrouver la forme d'entrée à partir de la forme fléchie. Il est économique en mémoire de stockage puisque les différentes données concernant une entrée ne sont enregistrées qu'une fois. Le temps de calcul est cependant très important, puisqu'il faut découper le mot pour retrouver la forme canonique.

2 - *Le dictionnaire de toutes les formes fléchies* occupe beaucoup plus de place (les différents traits sont répétés pour toutes les variantes d'un même mot) mais le calcul est très rapide, le traitement se bornant à une recherche du mot dans le dictionnaire.

Les avantages et les inconvénients se compensent de sorte que c'est la taille du dictionnaire dont on a besoin qui détermine la méthode appropriée. Pour des petits dictionnaires, dans le contexte d'un système expert ou d'un système d'E.A.O. (Enseignement Assisté par Ordinateur), on préfèrera stocker toutes les formes fléchies. Pour d'importantes masses de données, il faudra optimiser la vitesse d'accès au disque et les temps de réponse. L'efficacité des algorithmes de recherche dépend de la structuration des données.

Parmi les méthodes, peu nombreuses, nous citerons :

- la recherche dichotomique

avantages : Elle ne recourt à aucune structure de recherche, ce qui la rend d'autant

---

(1) La *base* est l'association d'un préverbe ou d'un préfixe à une racine.
(2) M. GROSS : "Une classification des phrases "figées" du français". *Revue Quebécoise de linguistique*, 11,2, Presses de l'Université du Quebec, Montréal, 1982
(3) L. DANLOS : "La morphosyntaxe des expressions figées", Langage n°63, *Formes syntaxiques et prédicats sémantiques*, Larousse, Paris, 1981

rapide en mémoire vive. L'emplacement des données recherchées n'a aucune influence sur la vitesse d'accès.

inconvénients : Les informations doivent être triées, ce qui est pénalisant pour la réactualisation du dictionnaire. L'insertion ou le retrait deviennent en effet très coûteux. Les enregistrements (entrées du dictionnaire avec les traits correspondants) doivent être de taille fixe, en pratique, ce qui implique un gaspillage de la mémoire. Dans le cas d'un tri sur une mémoire de masse (disque dur, bande ou cartouche), on n'élimine que la moitié de l'espace précédent à chaque accès disque.

- la méthode de l'adressage dispersé, (on calcule le numéro d'ordre du mot, dans le dictionnaire, et on lui associe une adresse disque dans une table de correspondance)

avantages : Les enregistrements peuvent être rangés dans le désordre et être de longueur variable. Il devient alors possible de les classer dans une autre perspective (pour accélérer la recherche de mots liés ou phonétiquement voisins par exemple). L'information est extraite très rapidement, généralement en un accès, parfois deux.

inconvénients : Lorsque l'on construit le dictionnaire ou au cours d'une recherche, les calculs peuvent donner le même résultat pour des mots distincts. L'actualisation du dictionnaire est très délicate et la table de correspondance encombre la mémoire vive. Le choix d'enregistrements fixes permet d'en faire l'économie. On peut également limiter les risques de collision en augmentant la marge de sécurité.

- la méthode des arbres de Bayer[1] présente les mêmes avantages avec un accès direct dans le dictionnaire. On représente la table de correspondance entre les mots et leurs adresses sous la forme d'un arbre n-aire. On range sur chaque noeud, une adresse et un pivot, en alternance.
On compare l'élément recherché au premier pivot. S'il est supérieur, on s'intéresse alors à l'adresse de droite (correspondant à un autre pivot dans l'arbre). S'il est inférieur, on s'intéresse à l'adresse de gauche (et on recommence avec le nouveau pivot).

avantages : méthode régulière, le temps de recherche est indépendant du mot cherché. La plus grande liberté est laissée au concepteur qui peut choisir les spécifications d'enregistrement (fixe ou variable) et le nombre des couples adresse-pivot attachés aux noeuds. Les ajouts ou les expressions dans le dictionnaire ne posent plus de problèmes et on peut se contenter de stocker un seul noeud dans la mémoire vive.

inconvénient : la mise en oeuvre informatique est assez complexe.

1.5.2.2 T. WINOGRAD

Le programme SHRDLU[2] fonctionne avec un dictionnaire construit sur les formes canoniques. Une méthode procédurale permet de partir d'une forme fléchie pour arriver à la forme canonique, ou inversement.

Le schéma ci-dessous, extrait de "Understanding Natural Language", (WINOGRAD 1972), s'applique à l'analyse de l'anglais. Il repose sur la suppression de certaines fins de mots et le rajout éventuel de séquences pour reconstruire la forme connue.

---

(1) D. KNUTH : *The Art of the Computer Programming*, volume 2, (2ème édition), Addison Wesley, Reading, Mass, 1973
(2) T. WINOGRAD : *Understanding Natural Language*, Academic Press, Edinburgh, 1972

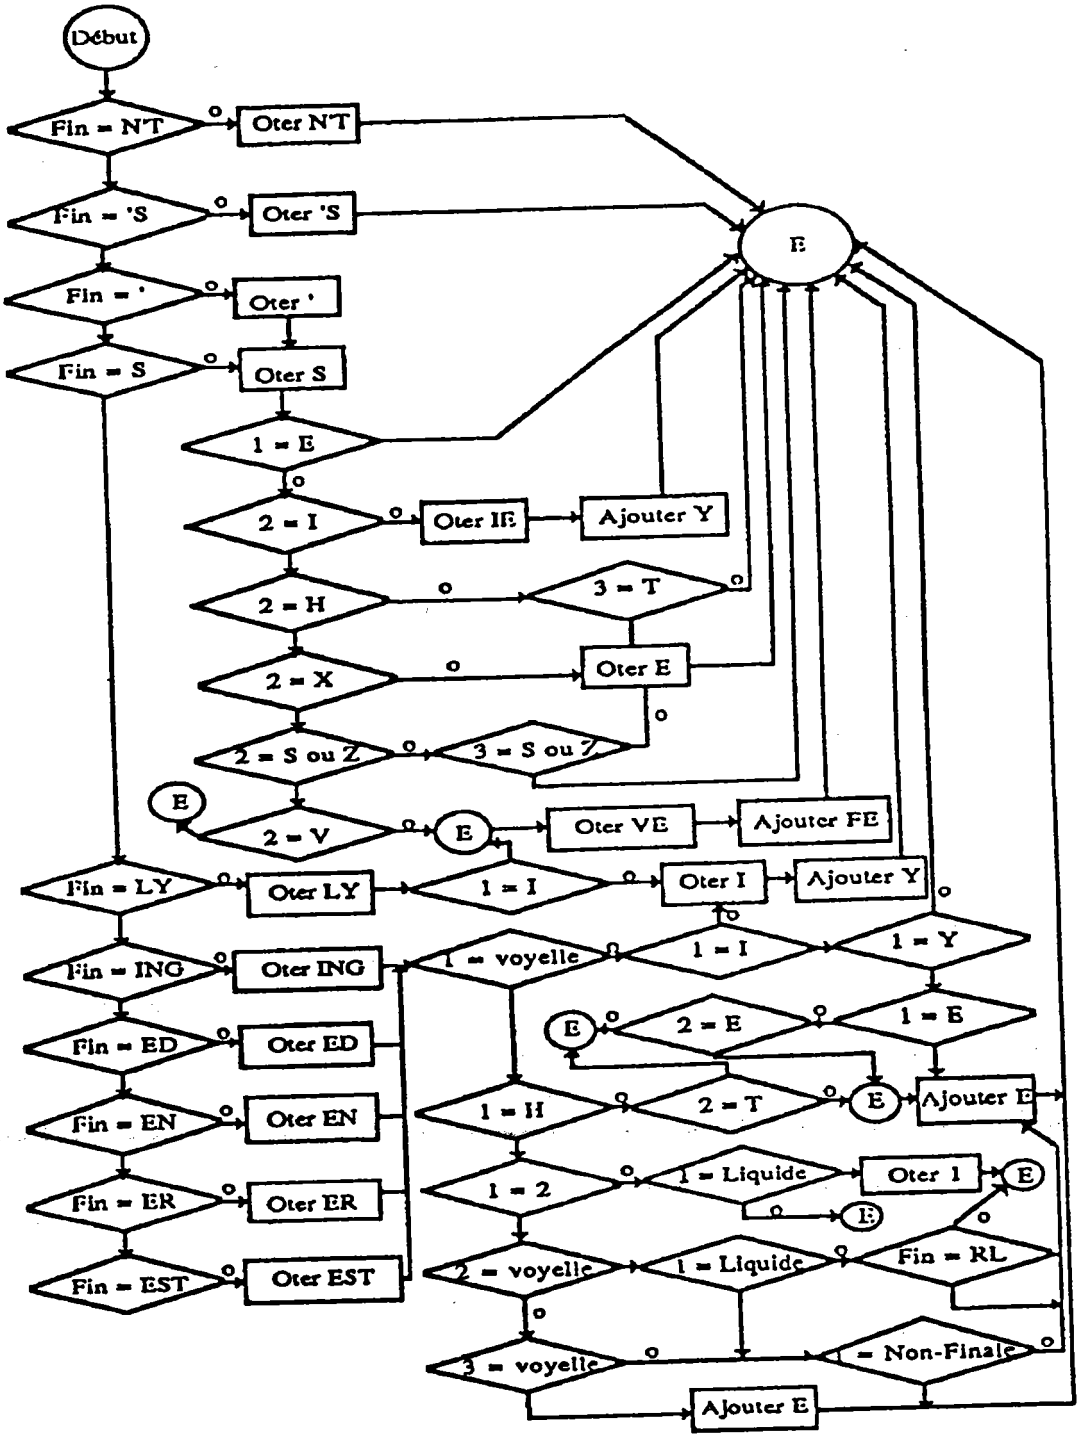

1. L'analyse débute par un test de comparaison entre la fin du mot et le segment spécifié par l'algorithme (**Fin** = *). S'il y a coïncidence, la fonction **Oter** débarrasse le mot analysé du segment prévu.
2. Les fonctions **1, 2, 3,** ... indiquent des lettres qui se trouvent à la fin du mot après qu'il ait été raccourci lors de l'étape précédente.

Dans le bas du schéma, à droite, on reconnaît des ensembles de lettres :
voyelles : a, e, i, o, u, y
liquides : l, r, s, v, z
non finales : c, g, s, v, z (que l'on ne peut trouver en fin de racine).
E est le test d'essai qui recherche dans le dictionnaire la présence de la chaîne de caractères obtenue.

exemple : *prettily - pretty*

1. test de la terminaison. On repère *ly* et on le supprime. *prettily - pretti*
2. **1**=I est vérifié, le mot se terminant par i.
ôter l : on ôte le i - *Prett*
ajouter y : on ajoute y - *Pretty*

exemple : *kisses - kiss*

1. test de la terminaison. On repère s et on le supprime. *kisses - kisse*
2. **1**=E est vérifié. Le mot se termine par e.
E n'aboutit pas, il n'y a pas de forme canonique *kisse*
2=S ou Z est vérifié. L'avant dernière lettre est bien un s
3=S ou Z également.
ôter E - *kiss*

Pour les exceptions, on ajoute des règles à l'algorithme ou on entre la forme dans le dictionnaire. Les résultats doivent ensuite être validés par des filtres de vérification morphosyntaxiques, ou désambiguïsés lors des étapes suivantes.

1.5.2.3 J. PITRAT

J. PITRAT[1] a construit un système qui fonctionne, en analyse et en génération, avec un dictionnaire contenant toutes les données d'une langue. Général dans son fonctionnement, il suffit de modifier les données pour l'adapter à une autre langue, cette propriété ayant été vérifiée sur 10 langues. Les données regroupent l'ensemble des mots (fichier mots), l'ensemble des désinences possibles (fichier terminaisons) et l'ensemble des conjugaisons/déclinaisons (fichier conjugaisons).

En considérant toutes les désinences a priori possibles, de la plus courte à la plus longue, le système examine pour chacune s'il existe une racine dans le lexique, (les racines sont recensées avec leurs variantes *recev, reçoi, reçoiv...* et les terminaisons qui peuvent leur être associées). Il vérifie que la nature grammaticale du mot ainsi trouvé concorde avec la désinence. Les ambiguïtés seront levées aux niveaux supérieurs.
Fichier des mots :

Mot	Nom de conjugaison	Racines
Tenir	Venir	Tien, ten, tienn, tin, tîn...

(1) J. PITRAT : "Réalisation d'un analyseur-générateur lexicographique général", *rapport de recherche* n°79/2, GR22, Institut de programmation, Paris VI, 1983

Fichier des terminaisons :

	Nom des terminaisons(T)	T1, T2, T3...Tn
(1)	VIP	s, s, t, ons, ez, ent
(2)	NMF	-, e, s, es

L'exemple (1) concerne ici les terminaisons (s, s, t, ons, ez, ent), pour certains verbes, à l'indicatif présent (VIP).
L'exemple (2) concerne les noms et les adjectifs (au masculin et au féminin) avec les désinences masculin sing., féminin sing., masculin plur., féminin plur.

Fichier des conjugaisons :

	conjugaison C	Groupe G	Terminaison T	i1, i2, i3...iq n° des racines
(1)	VENIR	IP	VIP	111223
(2)		II	VII	222222

La colonne 1 renvoie au fichier des mots, la colonne 3 au fichier des terminaisons.
La colonne 4 signifie que i1, i2, i3 = racine n°1, i4, i5 = racine n°2, i6 = racine n°3
L'entrée (1) de la figure ci-dessus indique que pour le groupe IP (Indicatif Présent), on utilise les terminaisons VIP (Verbe Indicatif Présent) et dans le cas présent (Tenir), on associe les trois premières désinences (T1=s, T2=s, T3=t) aux racines (I1=tien, I2=tien, I3=tien), puis les deux désinences suivantes (T4=ons, T5=ez) aux racines (I4=ten, I5=ten), et enfin T6=ent à I6=tienn.
Le chiffre 0 correspondra aux formes défectives.

L'analyse fonctionne de la droite vers la gauche. Les terminaisons du fichier sont utilisées sous une forme arborescente.

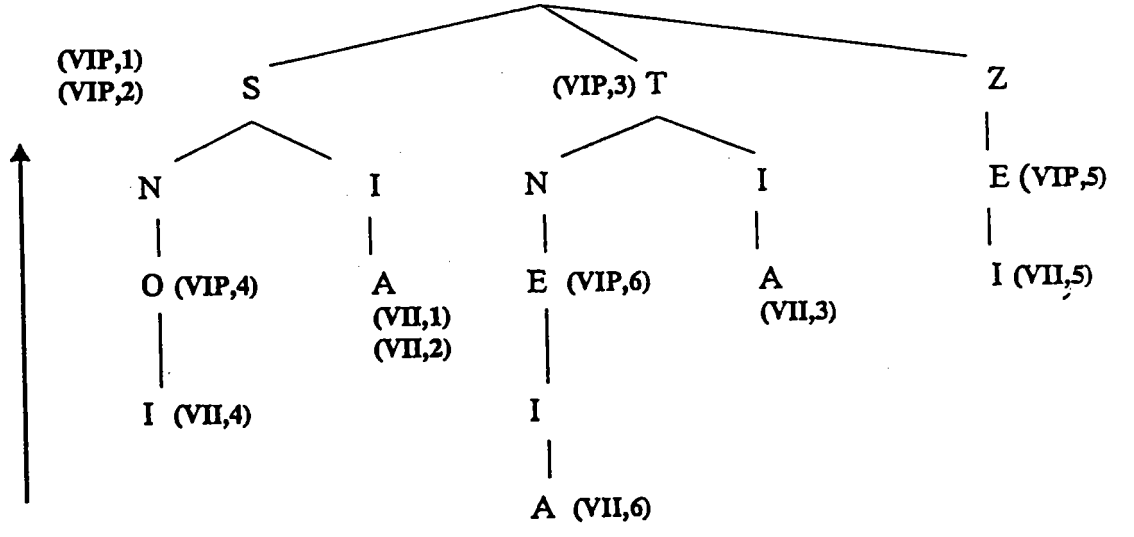

Chaque noeud contient le nom des terminaisons T qui correspond à la séquence allant du noeud au sommet, ainsi que sa position dans les terminaisons.

Soit la forme *TENAIENT* n=8
Le mot s'écrit a1, a2, a3, ...an.

Lors de l'analyse, on part de la gauche, en incrémentant le pointeur i d'un caractère.

Pour i=3, on a deux parties :

a1, a2, ...ai =*TEN*
an ...ai+2, ai+1 = *TNEIA*

On recherche la présence de *AIENT* dans l'arborescence. Si le test est vrai, on vérifie que la première partie a1, a2...ai est une racine connue.

L'opération de génération est bien plus directe que l'opération d'analyse car on possède toutes les informations utiles dès le départ.

L'organisation en arborescence accélère le traitement automatique. Il est intéressant, par conséquent, de présenter les racines sous cette même forme.

1.5.2.4 Problèmes annexes

L'analyse morphologique doit également tenir compte de phénomènes divers et essentiels, variables selon les langues.

- la ponctuation nécessite un traitement des ponctuations simples qui suivent immédiatement le mot, avec la reconnaissance des virgules et des points décimaux,
- les nombres composés, les expansions d'élision, les tirets de composition, les contractions
- la majuscule de début de phrase

En ce qui concerne les dictionnaires électroniques, nous avons cité le DELAS[1] et ses 50 000 entrées de formes canoniques, capables d'engendrer 350 000 formes fléchies. On peut ajouter le BDLEX[2]. Les dictionnaires évoluent sans cesse et ne seront jamais terminés. Les termes techniques, les néologismes, les sigles sont autant de défis.

Nous dirons en conclusion que l'organisation et l'utilisation d'un lexique dépend de l'application visée. L'exhaustivité, dans ce domaine, est impossible. Certaines études[3] ont mis au point des listes limitées, capables de couvrir de très nombreuses formes (4000 formes pour 90% des occurences d'un texte de français courant)[4]. La taille des lexiques ne pose pourtant pas de problèmes majeurs aux informaticiens qui savent gérer de grandes masses de données.

---

(1) G. GROSS : "Typologie des noms composés", *Rapport ATP CNRS*, Université Paris Nord Villetaneuse, 1986
(2) G. PERENNOU, M. de CALMES : "BDLEX base de données lexicale du français écrit et parlé", *Rapport du GRECO "Communication parlée"*, 1987
(3) G. GOUGENHEIM : *Dictionnaire fondamental de la langue française*, Didier, Paris, 1958
(4) N. CATACH : *Les listes orthographiques de base*, Collection Recherche, Nathan, Paris, 1984

Dès que la taille des lexiques devient importante, et puisqu'il est illusoire de vouloir recenser l'ensemble des mots utiles pour une application, il convient de prévoir une organisation incrémentielle[1] des lexiques[2].

La vocation du lexique est de mettre les constituants de base à la disposition des analyseurs syntaxiques et sémantiques. Les véritables difficultés sont de deux ordres.

- L'élément de base ne correspond pas toujours à un mot (locutions, mots composés...).

- La dépendance entre l'élaboration de la structure syntaxique et la composante sémantique. Il est impossible de mener concomitamment l'analyse des différents aspects d'un texte. On est donc souvent contraint de retenir une première hypothèse, en se ménageant des possibilités de retour en arrière.

1.5.3. Analyse de la phrase

Nous étudierons dans ce chapitre, les techniques informatiques qui permettront, à partir des constituants d'une phrase et des relations qu'ils entretiennent entre eux, de lui assigner une structure interne censée représenter sa "signification".

Ce mécanisme utilise des connaissances générales, externes, relatives à la langue et à l'univers contextuel. Présentées le plus souvent sous forme déclarative, elles recouvrent :

la grammaire avec les connaissances syntaxiques issues des modèles linguistiques que nous avons évoqués dans le paragraphe 1.4.

les mots : Ce sont les connaissances morphologiques et lexicales

les concepts : pour les connaissances sémantiques

le monde pour les données pragmatiques

Les rapports qu'entretiennent ces connaissances entre elles sont exprimées par des relations.

Ces connaissances, la grammaire plus particulièrement, sont étroitement liées à la forme de description chargée de représenter la phrase étudiée.

1.5.3.1 La grammaire et la description interne de la phrase

Cette influence des modèles linguistiques sur la représentation interne d'une phrase peut être importante lorsqu'il s'agit de systèmes fondés sur une théorie grammaticale. Nous verrons dans les paragraphes 1.5.7 (analyseurs conceptuels) et 1.5.4.3 (L'ATN) des analyseurs indépendants de toute théorie linguistique ou des mécanismes adaptables à diverses représentations.

---

(1) L'organisation incrémentielle permet d'étendre les lexiques pas à pas, c'est à dire d'y ajouter des enregistrements, un à un.

(2) Une méthode générale pour la constitution des lexiques et leur implémentation sur ordinateur est décrite dans : J. GOETSCHALCKX, L. ROLLING (eds.) : *Lexicography in the Electronic Age*, North Holland, 1982

A partir de la phrase *Frédéric casse des noix*, nous allons construire les structures correspondant à quelques modèles cités dans le chapitre 1.4.

La grammaire formelle (1.4.3.1) produit l'arbre ci-dessous :

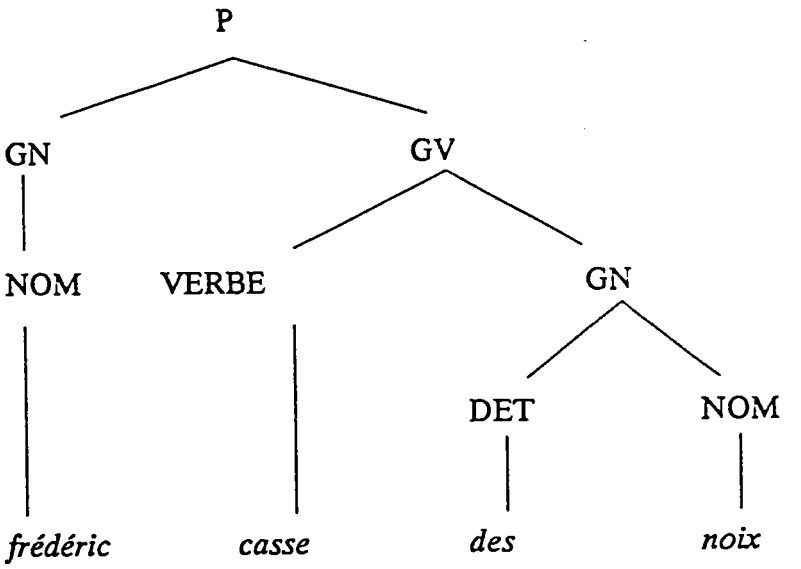

La grammaire de cas (1.4.3.3) construit un graphe avec des arcs étiquetés et introduit des notions sémantiques.

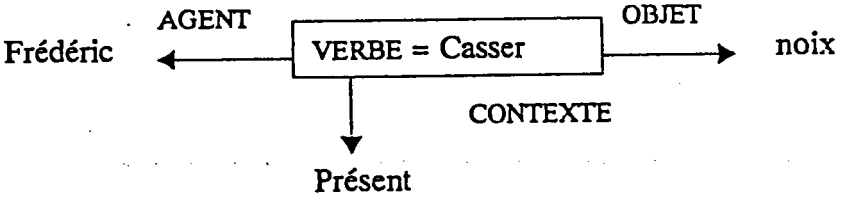

Les grammaires systémiques (2.5.3.5) introduisent des points de vue complémentaires.

Système de MODE	Principale, déclarative, assertion
Système d'ACTANTS	Agent : *Frédéric* Objet : *noix*, direct, pluriel
Système THEMATIQUE	Thème *Frédéric* Prédicat *casser(Frédéric, noix)*
Système INFORMATIF	connu : *Frédéric casse* nouveau : ce sont des noix qu'il casse

Les grammaires fonctionnelles (1.4.3.6.2) donnent une représentation plus complète.

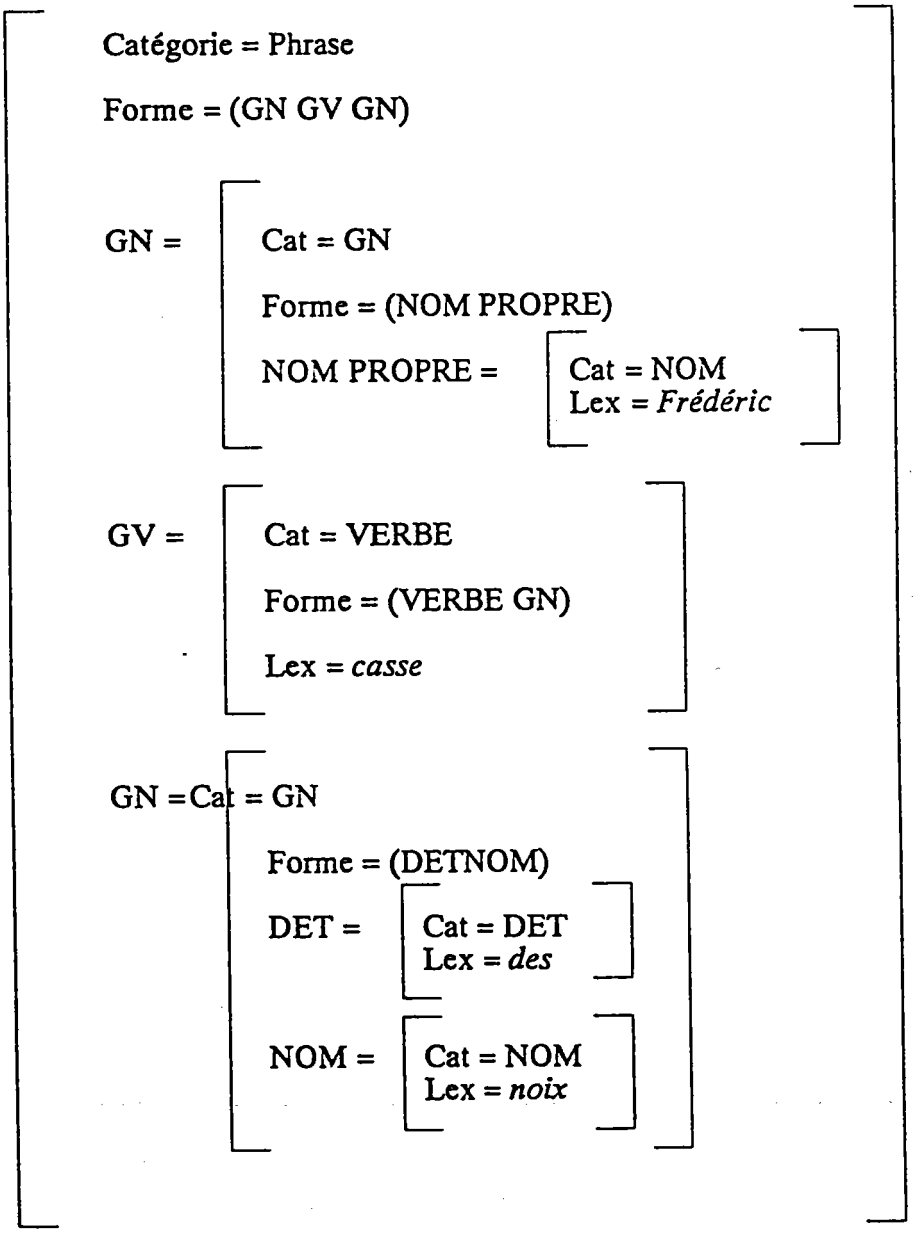

On constate que la représentation interne revêt des aspects assez différents selon le modèle dont elle est issue et contient plus ou moins d'informations sémantiques.

1.5.3.1.1 Syntaxe et sémantique

De nombreux aspects syntaxiques posent problème. Nous en avons relevés quelques uns déjà, (comparatifs/superlatifs, ellipses, anaphores, références, temps, portée des quantificateurs et de la négation...). Il n'existe pas de système capable de les résoudre tous. Chaque système dépend d'une application. Il correspond au niveau de complexité des phrases que l'on décide d'accepter ou au degré de grammaticalité que l'on tolère.

En construisant un arbre de précédence (N. CHOMSKY) ou un arbre de dépendance (I. MEL'CUK), l'analyseur syntaxique reconnaît la structure de la phrase traitée en iden-

tifiant le verbe, son sujet, et des objets... Les grammaires syntagmatiques généralisées (1.4.3.2.4.3) et les grammaires lexicales fonctionnelles (1.4.3.6.2) sont les plus utilisées actuellement. Parmi les nombreuses applications en T.A. et T.A.O. on peut citer ATLAS I (2.3.3.2.1), HICATS (2.3.3.2.2) et METAL (2.3.3.2.5).

Quel que soit le traitement ultérieur, l'analyse syntaxique doit montrer que des phrases distinctes peuvent avoir des structures identiques, si l'on veut traiter des transformations, des phénomènes particuliers (ellipses, anaphores...) et organiser une compréhension du sens.

On évoque ici la structure sémantique que l'on peut aborder en utilisant :

- des contraintes sémantiques qui, lorsqu'elles ne sont pas respectées, invalident les arbres syntaxiques construits

- des combinaisons de règles syntaxiques et de règles sémantiques qui, par interréaction, associent une représentation sémantique à la représentation syntaxique (grammaire de MONTAGUE et grammaires syntagmatiques généralisées 1.4.3.2.4.3)

Certains modèles privilégient plutôt la sémantique et intègrent une syntaxe simplifiée[1]. Ils s'appuient sur les grammaires sémantiques. D'autres modèles privilégient la pragmatique (Dialogues).

1.5.3.2 Traitement automatique

On peut considérer qu'il y a deux façons de procéder :

- l'analyse se déroule mot à mot, les décisions sont toutes prises au fur et à mesure et prises en compte dans l'élaboration des représentations.
- l'analyse peut revenir en arrière pour supprimer ce que G. SABAH[2] appelle les points d'embarras (état du système où les éléments de décision ne permettent pas d'opérer un choix parmi les traitements possibles). Les avantages sont certains, mais s'accompagnent d'une grosse consommation de mémoire et rallongent le temps de travail.
La majorité des systèmes réalisent une analyse mot à mot, de la gauche vers la droite.

1.5.3.2.1 L'architecture des systèmes

Les modules sont liés aux sources de connaissances qu'ils utilisent et reflètent de ce fait les distinctions classiques (morphologie, syntaxe, sémantique).

L'architecture traduit le type des interactions qu'ils entretiennent.

- Dans une architecture en série, les modules s'enchaînent, dans le même sens, le fonctionnement du module *n* n'ayant aucune influence sur celui du module *n-1*. Ceci peut être source d'ambiguïté artificielle.

---

(1) Y. WILKS : "An Artificial Intelligence Approach to Machine Translation", in : Computer Models of Thought and Language, Scank & Colby, Freeman, San Francisco, 1973, pp. 114-151

(2) G. SABAH : L'intelligence artificielle et le langage. Processus de compréhension, vol. n°2, Hermes, Paris, 1989, pp. 46-47

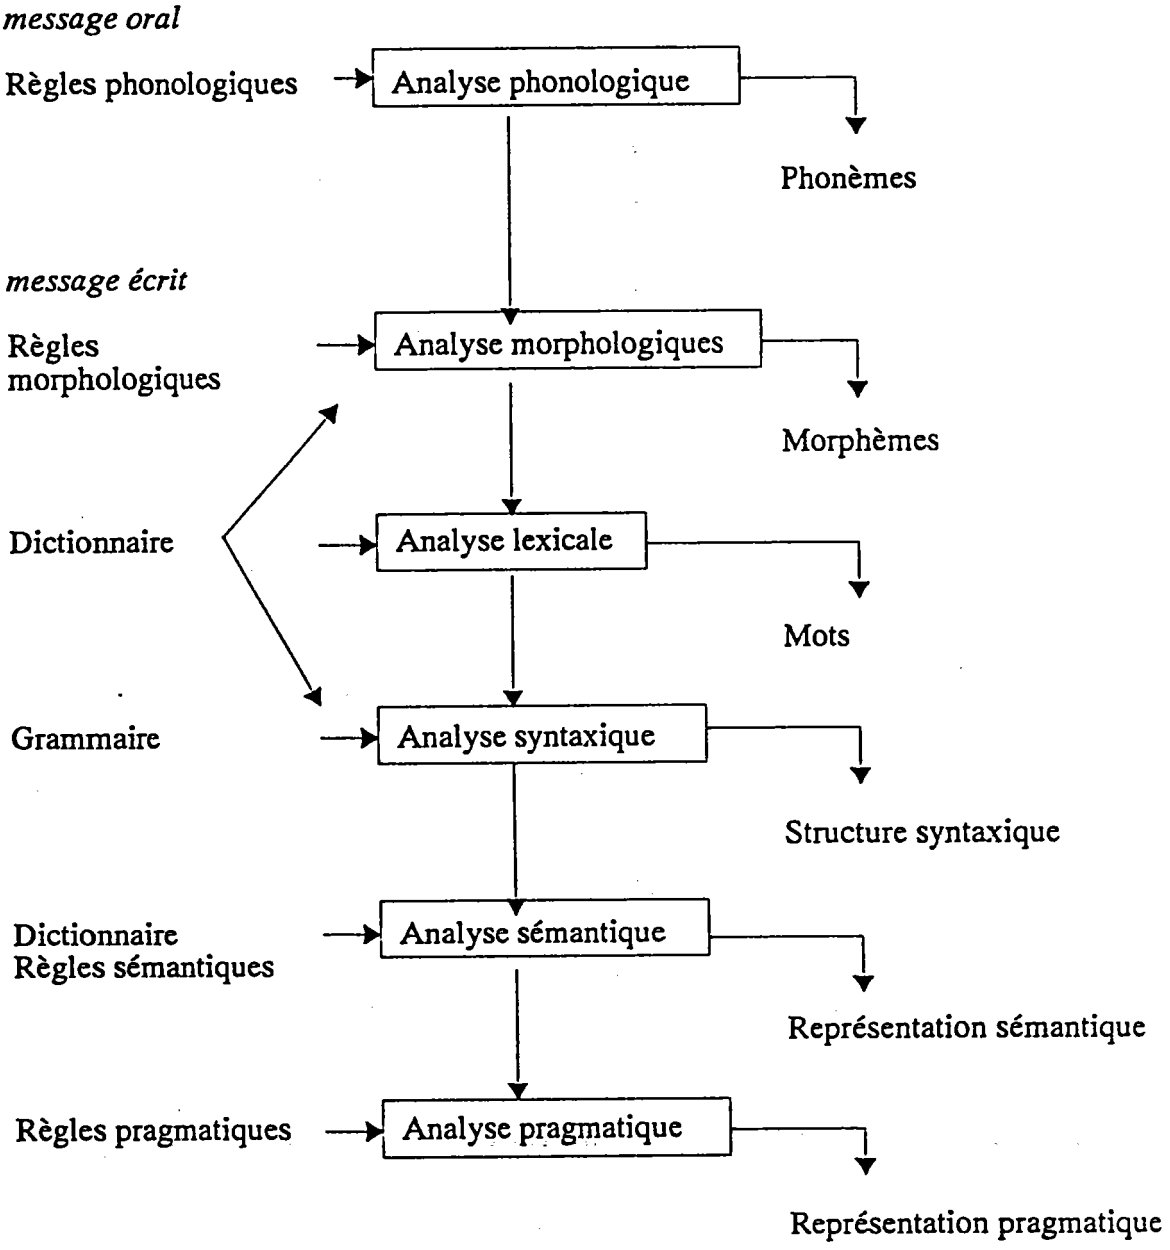

- *Dans une architecture hiérarchique*, l'analyse dépend d'un module principal. Le contrôle peut échoir à un sous module. Il n'y a jamais de retour en arrière. Si elle apporte quelques remèdes aux insuffisances d'une construction en série, elle est délicate à mettre en oeuvre et entraîne une limitation des interactions entre modules.

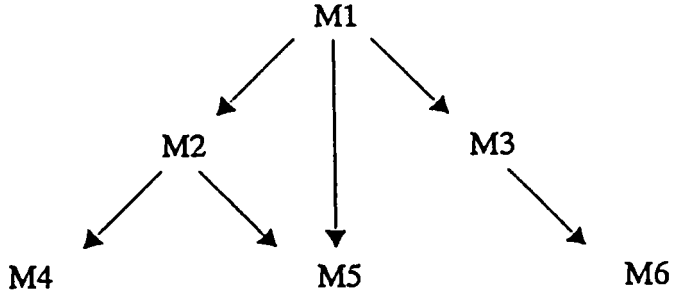

- *Dans l'architecture libre*, chaque module peut contrôler chaque module.

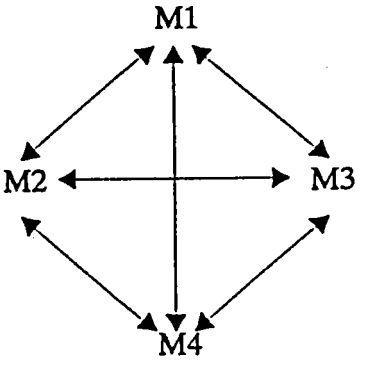

- Le seul moyen d'éliminer tous les points d'embarras est de renoncer à la modularité, au profit d'une intégration des éléments de décision qui rappelle l'organisation de certaines de nos connaissances. Ces dernières sont malheureusement si complexes que certains travaux[1,2] ont pu valider la méthode sur un plan théorique mais se sont heurtés à des problèmes de gestion insurmontables. T. WINOGRAD[3] s'était demandé *"comment concevoir un formalisme gardant les avantages de la décomposabilité sans sacrifier l'expression des interactions?"* avant de proposer la notion de **schéma** comme une première tentative de synthèse. Les recherches pour mieux contrôler les différentes sources de connaissances tout en conservant leur modularité ont conduit à la notion de **tableau noir**, qui permet à des bases de connaissances distinctes et considérées comme indépendantes d'intervenir ensemble, sans communiquer entre elles.

1.5.3.2.2 L'analyse

Construisons une grammaire de type génératif capable d'engendrer la phrase :

Un arbre cache la forêt

1. P -> GN GV
2. GN ->DET NOM
3. GV -> VERBE GN
4. DET -> *un / la*
5. NOM -> *arbre / forêt*
6. VERBE -> *cache*

Le processus qui consiste, en partant du symbole P, à le remplacer par la partie droite, (Les nouveaux symboles pouvant être à leur tour réécrits par l'application de nouvelles règles qui peuvent intervenir plusieurs fois), est un processus de génération.

---

(1) **M. RADY** : "L'ambiguïté du langage naturel est-elle la source du non-déterminisme des procédures de traitement ?", *Thèse de Doctorat ès Sciences*, Paris, Université Pierre et Marie Curie, 1983
(2) **L. SELIGMAN** : "Intégration de la syntaxe, de la sémantique et de la pragmatique dans un analyseur de textes. Application à l'avionique." *Thèse de l'Université Pierre et Marie Curie*, Paris, 1985
(3) **T. WINOGRAD** : *Understanding Natural Language*, Academic press, Edinburgh, 1972

Or notre but est de réaliser une analyse. Il nous faut donc, en partant de la phrase à analyser, choisir les règles qui nous mèneront au résultat, en fonction des mots de la phrase.
Nous disposons de deux méthodes :
- L'analyse descendante, dirigée par les hypothèses, part de P et compare avec la phrase. S'il y a correspondance entre les éléments le plus à gauche, on les élimine, sinon on réécrit l'élément en appliquant une règle possible.

P	*un arbre cache la forêt*
GN/GV	*un arbre cache la forêt*
DET/NOM/GV	*un arbre cache la forêt*
un/NOM/GV	*un arbre cache la forêt*
NOM/GV	*arbre cache la forêt*
arbre/GV	*arbre cache la forêt*
GV	*cache la forêt*
VERBE/GN	*cache la forêt*
cache/GN	*cache la forêt*
GN	*la forêt*
DET/NOM	*la forêt*
la/NOM	*la forêt*
NOM	*forêt*
forêt	*forêt*

L'application successive des règles 1, 2, 4, 5, 3, 2, 4, 5 permet de construire l'arbre syntaxique de la phrase.

- Avec l'analyse montante, dirigée par les données, on part des mots de la phrase pour arriver aux structures grammaticales possibles.
On lit le mot puis on lui substitue une catégorie. On essaie ensuite de réécrire ces éléments pour arriver à P, en appliquant les règles à l'envers. (on réécrit le membre droit par le membre gauche). Quand on reconnaît une séquence, on la remplace par la catégorie correspondante.

un arbre cache la forêt

règle 4	DET *arbre cache la forêt*
règle 5	DET NOM *cache la forêt*
règle 2	GN *cache la forêt*
règle 6	GN VERBE *la forêt*
règle 4	GN VERBE DET *forêt*
règle 5	GN VERBE DET NOM
règle 2	GN VERBE GN
règle 3	GN GV
règle 1	P

Les deux méthodes peuvent être à l'origine d'ambiguïtés artificielles. Certains chercheurs[1] prônent l'utilisation conjointe des deux techniques.
T. WINOGRAD a traité ces aspects dans le détail[2].
Les exemples que nous avons choisis ne présentent aucune difficulté pour les analyseurs. Différentes techniques ont été élaborées afin que le système, comparé à un point

---

(1) Groupe Langage et Cognition du LIMSI, Université Pierre et Marie Curie, Paris
(2) T. WINOGRAD : *Language as a Cognitive Process, Volume I, Syntax*, Addison Wesley, pp. 93-109, 1983

d'embarras, puisse fonctionner malgré l'insuffisance des critères de décision. Le traitement en parallèle consiste à construire toutes les solutions possibles, pour chaque point d'embarras. La production de toutes les analyses, à propos d'un énoncé, exige énormément de temps calcul.

La statégie de retour en arrière consiste à privilégier arbitrairement une solution parmi les solutions possibles. Celles qui sont rejetées sont stockées dans une pile avec toutes les informations décrivant l'état du système, et ceci, pour chaque point d'embarras. Lorsque l'analyse est dans l'impasse, on repart du sommet de la pile après avoir remis le système dans l'état correspondant.
Lorsque le système est bloqué et que la pile est vide, il y a échec de l'analyse.
On peut assouplir cette stratégie en classant les décisions a priori ou en les choisissant selon des heuristiques. Le système placé sur un point d'embarras prendra alors les décisions les plus probables. (Réseaux de Transitions Augmentés, paragraphe 1.5.4.3).

La plupart des analyseurs préfèrent la stratégie du retour en arrière, malgré l'inconvénient d'un temps d'analyse qui peut devenir très long, si les mauvaises solutions sont utilisées d'abord. Ces stratégies non déterministes ne sont pas forcément indispensables, comme nous le verrons dans le paragraphe 1.5.5 à propos des analyseurs déterministes. La notion de "table" cherche à intégrer les avantages des deux méthodes sans en avoir les inconvénients. **J. KAPLAN**[1] a imaginé une structure de données adaptée à un traitement optimal des possibilités multiples. Son algorithme n'effectue que le traitement approprié à une situation donnée, et ne l'effectue qu'une fois. Il introduit la notion de "**chart**" pour représenter la grammaire et la structure de la phrase. Les arcs de l'arbre traduisent les relations verticales (dominance) et les relations horizontales (précédence). Pour obtenir une table, on modifie l'arbre selon deux axes. Les arcs sont transformés pour produire un arbre binaire. Les arcs et les noeuds sont échangés : les arcs de l'arbre devenant les sommets du chart et les noeuds de l'arbre devenant ses arêtes. Les sommets représentent alors les séparateurs de mots, et les arêtes les mots ou séquences de mots.

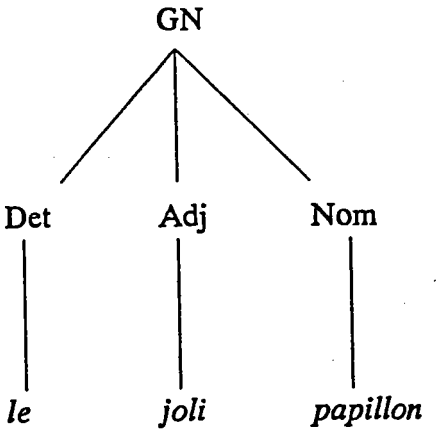

Relations de dominance : explicites
Relations de précédence : implicites

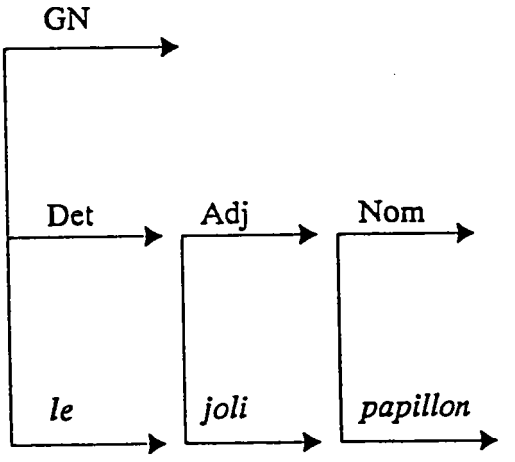

Relations de dominance : implicites
Relations de précédence : explicites

---

(1) **J. KAPLAN** : "A General Syntactic Processor" in *Natural Language Processing*, Rustin, Algorithmic Press, New York, pp. 193-241, 1979

La table peut coder un ensemble d'arbres disjoints :

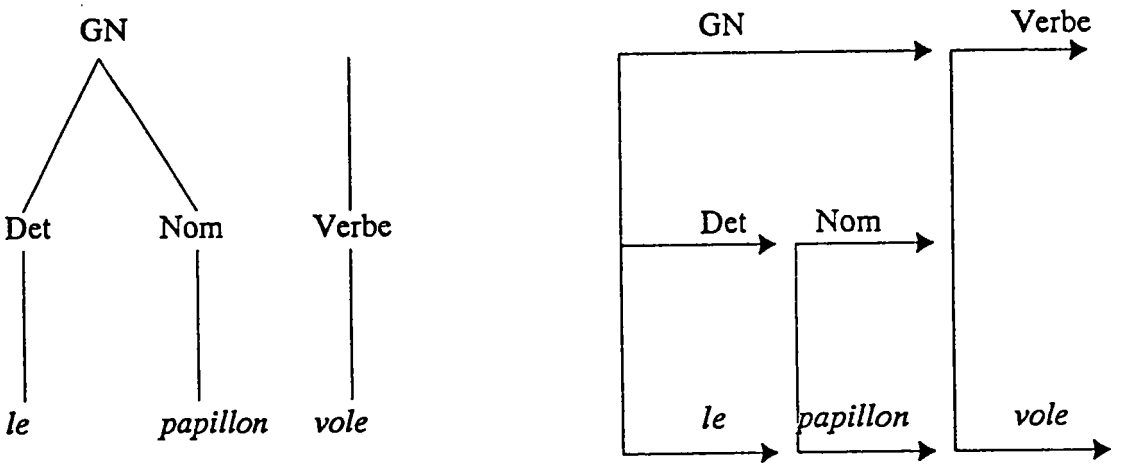

On peut également représenter les ambiguïtés, en reliant deux mêmes noeuds par plusieurs arêtes. Les étiquettes de ces arêtes indiqueront les interprétations correspondantes.

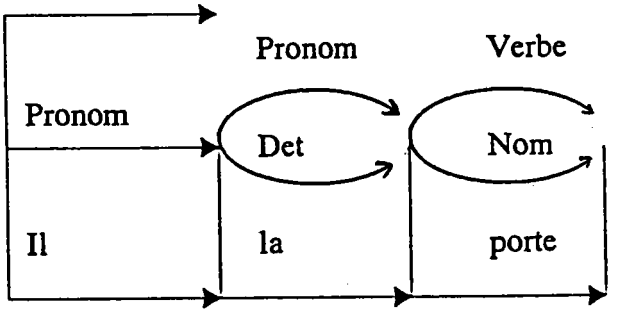

1.5.3.3 Exemples

Pour illustrer les paragraphes précédents, nous présentons des analyseurs qui ne seront pas étudiés dans le détail, par la suite. Nous les classerons en fonction des grammaires utilisées, qui seront, dans le cas présent, des grammaires formelles.

Grammaires indépendantes du contexte

- *"L'analyseur prédictif" de Harvard*[1] : Cet analyseur descendant est basé sur une grammaire non contextuelle (133 classes de mots, 2100 règles)[2]. La taille de cette grammaire s'est vite révélée très insuffisante et les temps de calcul beaucoup trop longs (1 minute pour une phrase de 18 mots sur les ordinateurs de l'époque).

.(1) S. KUNO, A. OETTINGER : "Multiple Path Syntactic Analyser" in *Information Processing*, North Holland, Amsterdam, 1962

(2) S. KUNO : "The Multiple Path Syntactic Analyser for English", *Rapport NSF-9, Mathematical Linguistics and Automatic Translation*, Computation Laboratory, Harvard University, Cambridge Mass., 1963

L'utilisation d'une matrice destinée à supprimer les essais inutiles[1] n'a pas réussi à démentir le fait que ce type de formalisme n'était pas vraiment adapté au traitement automatique.
- *L'analyseur en constituants immédiats*[2] : Développé chez RAND, il est basé sur un algorithme montant rapide, qui occupe une place importante en mémoire et utilise des règles de grammaire écrites sous la forme normale de N. CHOMSKY.

Grammaires transformationnelles

- *Le système de Z. HARRIS*[3] : à stratégie montante, il est basé sur une grammaire en chaîne et reconnaît divers types de chaînes d'une grammaire qui correspond à des règles non contextuelles. Si les analyseurs concernaient les phrases isolées, Z. HARRIS imagine les processus de transformation pour relier des phrases qui ont des éléments en commun.
L'analyse est plus complexe qu'avec une grammaire à structures de phrases.

- *Le système de A. ZWICKI*[4] : Basé sur une grammaire transformationnelle générative (275 règles et 54 transformations pour le module de base), il dispose d'un ensemble de 550 règles et de 134 transformations inverses (36 minutes pour analyser une phrase de 12 mots).

Pour l'améliorer, D. WALKER[5] a proposé la notion de "super-arbre", identique au chart de J. KAPLAN, et de règles de rejet.

- *Le système de S. PETRICK*[6,7] était plus général donc plus lent encore que le système de A. ZWICKY. Il a été complètement remanié[8] et est utilisé comme analyseur dans un système de question-réponse[9] où il analyse des requêtes en moins d'une minute[10].

Grammaires en chaîne

Les théories de Z. HARRIS sont peu utilisées mais présentent deux avantages pour l'automatisation.
- La structure en chaîne et la structure transformationnelle d'une phrase sont en correspondance étroite. L'analyse en chaîne est d'autant plus adaptée à une décomposition transformationnelle.

---

(1) S. KUNO : "The Predictive Analyser and a Path Elimination Technique", *Communications ACMG 8*, 7, pp. 453-462, 1965
(2) D HAYS : *Introduction to Computational lLnguistics*, American Elsevier, New York, 1967
(3) Z. HARRIS : *String Analysis of Sentence Structure*, Mouton and Co, La Hague, 1962
(4) A. ZWICKY, J. FRIEDMAN, B. HALL, D. WALKER : "The MITRE Syntactic Analysis Procedure for Transformational Grammars", *Actes Fall Joint Computer Conference*, Thompson Books, Washington DC, 1965
(5) D. WALKER, P. CHAPLIN, M. GEIS, L. GROSS : "Recents Developments in the MITRE Syntactic Analysis Procedure", *Rapport MITRE MTP.11*, 1965
(6) S. PETRICK : "A Recognition Procedure for Transformational Grammars", *Thèse de PhD*, dep. Modern Languages, MIT, Cambridge, Mass., 1965
(7) S. PETRICK : "A Program for Transformational Syntactic Analysis". *Rapport AFCRL-66-698*, Air Force Cambridge Research Laboratory, 1966
(8) S. PETRICK : *Transformational Analysis in Natural Language Processing*, Rustin, Algorithmics Press, New York, 1973
(9) W. PLATH : REQUEST : "A Natural Language Question-answering System", *IBJ Journal of research and development*, 20, 4, pp. 326-335, 1976
(10) F. DAMERAU : "Operating Statistics for the Transformational Question-answering System", *American Journal of computational linguistics*, 7, 1, pp. 32-40, 1981

- La grammaire en chaîne décrit facilement certaines relations entre constituants, car elle est assez proche des structures de surface.

- *L'analyseur de N. SAGER* a bénéficié des améliorations apportées par R. GRISHMAN[1] avec "le langage de restrictions" et J. HOBBS[2] avec un mécanisme d'analyse transformationnelle.

- *L'analyseur de J.H. JAYEZ*[3] traite des intitulés en français à l'aide d'une grammaire en chaîne du français développée par M. SALKOFF[4].

Grammaires contextuelles

- *Le système DEACON* (Direct English Access and Control) a été développé pour l'armée, chez General Electric[5]. Basé sur une grammaire contextuelle, le système est un des premiers à organiser des ponts systématiques entre le composant syntaxique et un composant sémantique. W. WOODS[6] a construit un algorithme pour améliorer les performances de ce type d'analyseur qui produisait des analyses redondantes.

Grammaires de type 0

- *Le système de M. KAY* utilise les règles de réécriture non restreintes, auxquelles on ajoute des mécanismes de restriction qui n'entament pas le pouvoir génératif de la grammaire mais en facilitent l'écriture. Inclus dans le système REL (Rapidly Extensible Language)[7], il fait appel à une grammaire de 239 règles.

- *Le système Q de A. COLMERAUER*[8] fonctionne également avec des règles non restreintes. Ce système a été utilisé dans le projet de traduction automatique de l'université de Montréal[9].

- Hewlett-Packard a développé un analyseur basé sur les GPSG de G. GAZDAR (Generalized Phrase Structure Grammars)[10]. Des métarègles développent les règles de la grammaire non contextuelle, avant l'analyse de la phrase. (40 règles et 10 métarègles produisent une grammaire finale de 283 règles). Le système analyse les interrogations d'une base de données relationnelle.

---

(1) R. GRISHMAN : "Implementation of the String Parser of English" in *Natural Language Processing*, Rustin, Algorithmics Press, New York, 1973

(2) J. HOBBS, R. GRISHMAN : "The Automatic Transformational Analysis of English Sentences : an Implementation", *International Journal of Mathematics*, section A, 5, pp. 267-283, 1976

(3) J.H. JAYEZ : "Une approche de la compréhension par machine du langage naturel", *Thèse d'Etat*, Paris VII, 1979

(4) M. SALKOFF : *Une grammaire en chaîne du français. Analyse distributionnelle*, Paris, Dunod, 1973

(5) J.A. CRAIG, S.C. BERENZER, H.C. CARNOY, C.R. LONGYEAR : "DECON : Direct English Access and Control", *Actes Fall Joint Computer Conference*, Thompson Books, Washington DC, 1966

(6) W. WOODS : "Context-sensitive Parsing", *Communications ACM*, 13, 7, pp. 437-445, 1970

(7) F. THOMPSON, P.C. LOCKEMAN, B. DOSTERT, R.S. DEVERILL : "REL : a Rapidly Extensible Language System", *Actes de la 24ème conférence nationale ACM*, 1969

(8) A. COLMERAUER : "Les systèmes Q ou un formalisme pour analyser et synthétiser des phrases sur ordinateur", *publication interne n°43*, Faculté des Sciences, Université de Montréal, 1970

(9) R. KITTREDGE et al. : *TAUM73 Rapport sur le projet de traduction automatique de l'université de Montréal*, 1973

(10) J.M. GAWRON et al. : "Processing English with a Generalized Phrase Structure Grammar", *Actes du 20ème séminaire annuel de l'association Computational Linguistics*, pp. 74-81, 1982

Grammaires systémiques

- *Le programme de T. WINOGRAD* est un des rares à avoir utilisé ce type de grammaire. Il intègre sous une forme procédurale, les modules syntaxiques, sémantiques et pragmatiques.

1.5.4. Les réseaux de transitions

1.5.4.1 Introduction

Pour mettre en oeuvre les différents modules qui décrivent la structure des phrases, on dispose de certaines procédures qui ne leur sont pas totalement liées.

Les grammaires formelles et transformationnelles donnent des modèles orientés vers la génération. Bien que leur utilisation pour l'analyse soit difficile, nous avons cité quelques réalisations dans le paragraphe 1.5.3.3. Les algorithmes opèrent des transformations inverses et dont le nombre croît exponentiellement.
Ces difficultés ont conduit les chercheurs à substituer aux règles de grammaire la notion de "représentation des formes de phrases acceptables". A la suite des travaux de S. KUNO[1] avec l'élaboration d'une procédure exprimant les transformations inverses sous forme de réseaux, les chercheurs ont tenté d'utiliser directement ces réseaux pour l'analyse de la langue.
Le principe de ces réseaux[2] est de "réunir les parties droites des règles d'une grammaire hors-contexte qui ont la même partie gauche en un diagramme explicitant les transitions correspondantes. Pour décrire des phrases comme :

La jeune fille chante
Le vilain chat griffe le facteur

on pourra utiliser les séquences :

DET ADJ NOM VERBE
DET ADJ NOM VERBE DET ADJ NOM

Une représentation[3] plus économique serait :

(PRON ∪ (DET ADJ * NOM)) VERBE { (DET ADJ * NOM) }

∪ symbole d'alternative (on peut remplacer DET ADJ * NOM par un pronom)
* symbole de répétition (*la fille, la jeune fille, la belle jeune fille, la belle grande jeune fille...*)
{...} le segment est optionnel

Le réseau de transitions permet d'éviter ce type de notation très lourde dans le cas de phrases complexes.

---

(1) S. KUNO : "A System for Transformational Analysis", *Rapport NSF-15, Mathematical Linguistics and Automatic Translation*, Computation Laboratory, Harvard University, Cambridge, Mass., 1965
(2) M. CONWAY : "Design of a separate transition-diagram compiler" in *Communication ACM 6, 7*, pp. 396-408
(3) Notation développée par S. KLEENE à propos des langages réguliers (*Introduction of mathematics*, Van Nostrand, 1952)

On imagine alors le réseau de transitions, qui a l'allure d'un **graphe** formé d'états (a, b, c) reliés par des **arcs** orientés. Ces arcs représentent des transitions entre les états.
On distingue, parmi les états, l'**état initial** (-->) et l'**état final**. Les arcs sont étiquetés par des mots ou des catégories lexicales. La suite des étiquettes lues de toutes les façons à partir d'un état initial jusqu'à un état final, correspond aux phrases définies par le réseau. Pour analyser la phrase, on pointe les mots, de la gauche vers la droite, en essayant de relier un point initial et un point final.

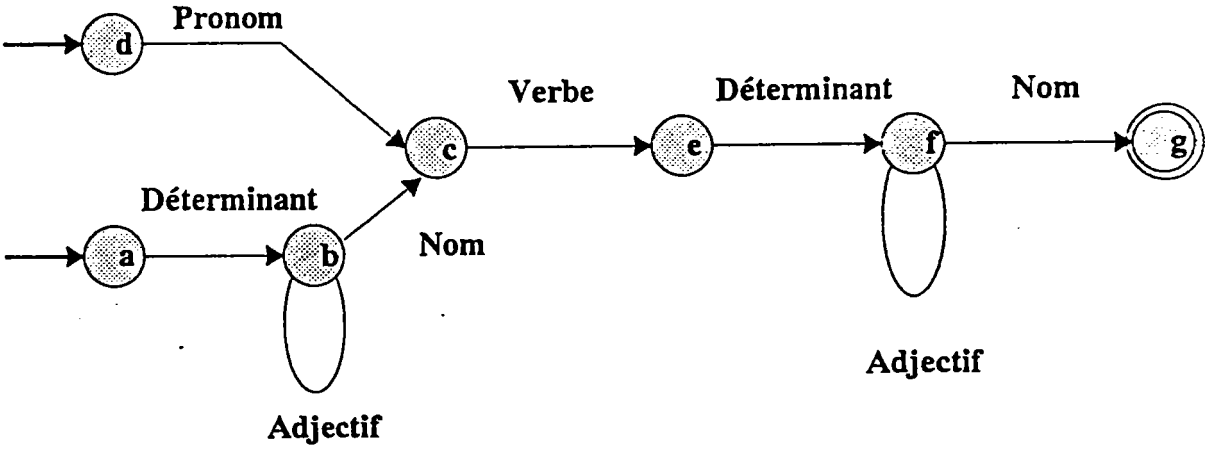

Analyser une phrase, c'est lire les mots, un par un, en partant de la gauche vers la droite et en cherchant à relier un état initial à un état final. Une méthode non déterministe d'analyse descendante utiliserait un réseau de transitions représentant la grammaire et un dictionnaire (indications sur les mots et les catégories lexicales). A partir d'un état initial, le programme effectue une boucle sur les mots de la phrase à analyser. Pour chaque état, il choisit un arc sortant. S'il n'y a pas d'arc sortant, l'analyse avorte.
Si le mot pointé correspond à l'étiquette, l'état courant est l'état terminal de l'arc parcouru. Sinon, il y a échec. Quand tous les mots sont lus, le dernier état courant doit être un état final pour que l'analyse se solde par un succès. Dans le cas contraire, il y a échec. Il faut préciser, au cours de l'analyse, la manière d'opérer certains choix ou la marche à suivre en cas d'échec, ce qui renvoie aux techniques d'analyse en parallèle et d'analyse avec retour en arrière décrites au paragraphe 1.5.3.2.2.
Pour une analyse en parallèle de *la porte ferme le couloir*[1] nour aurons :
Mot lu : *la*
A partir des noeuds a et d on peut atteindre les noeuds b et c par l'arc a-b (*la* peut être déterminant) et par l'arc d-c (*la* peut être pronom). Nous sommes en b et en c.
Mot lu : *porte*
A partir de b et de c on peut atteindre les noeuds c et e par l'arc b-c (*porte* n'est pas un adjectif mais peut être un nom) et par l'arc c-e (*porte* peut être un verbe). Nous sommes en c et en e.

---

(1) Exemple emprunté à G. SABAH : L'intelligence artificielle et le langage. Processus de compréhension, Hermes, Paris, 1989, p. 77

Mot lu : *ferme*
A partir de c on peut atteindre e par l'arc c-e (ferme est un verbe). L'autre possibilité, c'est à dire l'emprunt de l'arc e-f est impossible. Nous sommes en e.
Mot lu : *le*
On atteint f par l'arc e-f
Mot lu : *couloir*
On atteint g par l'arc fg. L'analyse se termine avec succès puisque g est un noeud terminal.

L'analyse avec retour arrière utilise une pile dans laquelle sont stockés les états du système selon le schéma [Position, {Arcs à essayer}]. Le signe + dans la colonne ACTION indique une correspondance entre le mot lu et la catégorie de l'arc. Le signe - indique qu'ils ne se correspondent pas.

PILE (avant)	MOT LU	ARC COURANT	ACTION	PILE (après)
[1, {d-c, a-b}]	*la*	d-c	+	[1, {a-b}]
[2,{c-e}] [1,{a-b}]	*porte*	c-e	+	[2,{φ}] [1,{a-b}]
[3, {e-f}] [2,{φ}] [1,{a-b}]	*ferme*	e-f	-	[3, {φ}] [2,{φ}] [1,{a-b}]
[3, {φ}] [2,{φ}] [1,{a-b}]	*ferme*	φ		[2,{j}] [1,{a-b}]
[2,{j}] [1,{a-b}]	*porte*	φ		[1,{a-b}]
[1,{a-b}]	*la*	a-b	+	[1, {φ}]
[2, {b-b, b-c}] [1, {φ}]	*porte*	b-b	-	[2, {b-c}] [1, {φ}]
[2, {b-c}] [1, {φ}]	*porte*	b-c	+	[2, {φ}] [1, {φ}]
[3, {c-e}] [2, {φ}] [1, {φ}]	*ferme*	c-e	+	[3, {φ}] [2, {φ}] [1, {φ}]
[4, {e-f}] [3, {φ}] [2, {φ}] [1, {φ}]	*le*	e-f	+	[4, {φ}] [3, {φ}] [2, {φ}] [1, {φ}]
[5, {f-f, f-g}] [4, {φ}] [3, {φ} [2, {φ}] [1, {φ}]	*couloir*	f-f	-	[5, {f-g}] [4, {φ}] [3, {φ}] [2, {φ}] [1, {φ}]
[5, {f-g}] [4, {φ}] [3, {φ}] [2, {φ}] [1, {φ}]	*couloir*	f-g	+	[5, {φ}] [4, {φ}] [3, {φ}] [2, {φ}] [1, {φ}]

Le noeud g est un noeud terminal. Après avoir lu le dernier mot, l'analyse se termine par un succès.

Il est clair, ici, qu'il ne s'agit que d'une procédure de reconnaissance. Cette procédure permet de vérifier si une phrase correspond à un réseau mais ne détermine en aucune façon sa structure. La puissance de ce formalisme est équivalente aux grammaires régulières (grammaires formelles de type 3). Pour atteindre une équivalence avec les grammaires de type 2 (grammaires indépendantes du contexte) et obtenir une analyse de la phrase, il faut étendre le modèle. On réunit alors des réseaux de transitions étiquetés et l'on parle d'un réseau de transitions **récursif.**

1.5.4.2 Le R.T.N. ("Recursive Transition Network")

Lorsque les étiquettes d'un réseau sont des catégories syntaxiques (P, GN, GV, GP...), on obtient un ensemble de réseaux de transition étiquetés. Cet ensemble constitue un réseau de transitions récursif, dans le sens où, dans un réseau donné, un arc peut appeler ce réseau.
Issus des automates d'états finis, avec quelques ajouts (aspect récursif), ces réseaux sont équivalents, en puissance d'expression, aux grammaires indépendantes du contexte.

Considérons l'automate suivant :

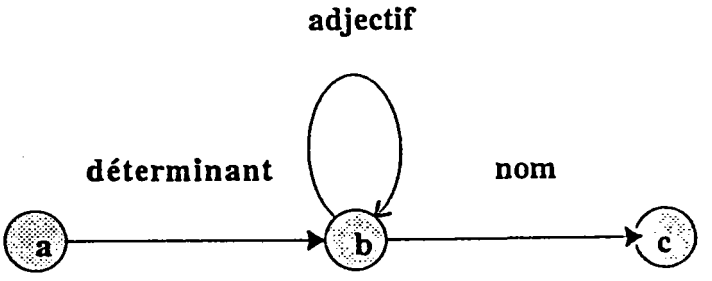

Une phrase est acceptée si, en partant de l'état initial avec le début de la phrase, on peut atteindre un état final à la fin de la phrase. L'automate représenté peut accepter des phrases du type "*le joli papillon*", "*le beau livre*", "*le joli petit cadeau*" mais pas "*joli papillon*".
Il n'est pas possible, avec ce modèle, de représenter récursivement des phrases comme "*le beau chien de la soeur de l'ami de notre voisin*".
En spécifiant sur les arcs, non seulement des symboles terminaux (qui donnent un accès direct aux mots du langage) tels que **déterminant, verbe, nom** mais aussi des symboles non terminaux tels que GN (groupe nominal) ou GP (groupe prépositionnel) définis eux-mêmes par un autre automate pouvant faire référence à l'automate dont il fait partie, on arrive à la notion de RTN (Recursive Transition Network), dont nous présentons un exemple très simple.
Les catégories terminales sont ici **préposition, adjectif, verbe, Déterminant** et **nom.**
Les catégories non terminales sont GN (groupe nominal) et GP (groupe prépositionnel).
Un GN contient ici un GP et réciproquement. Il est donc essentiel d'employer un langage de programmation qui autorise la récursion.

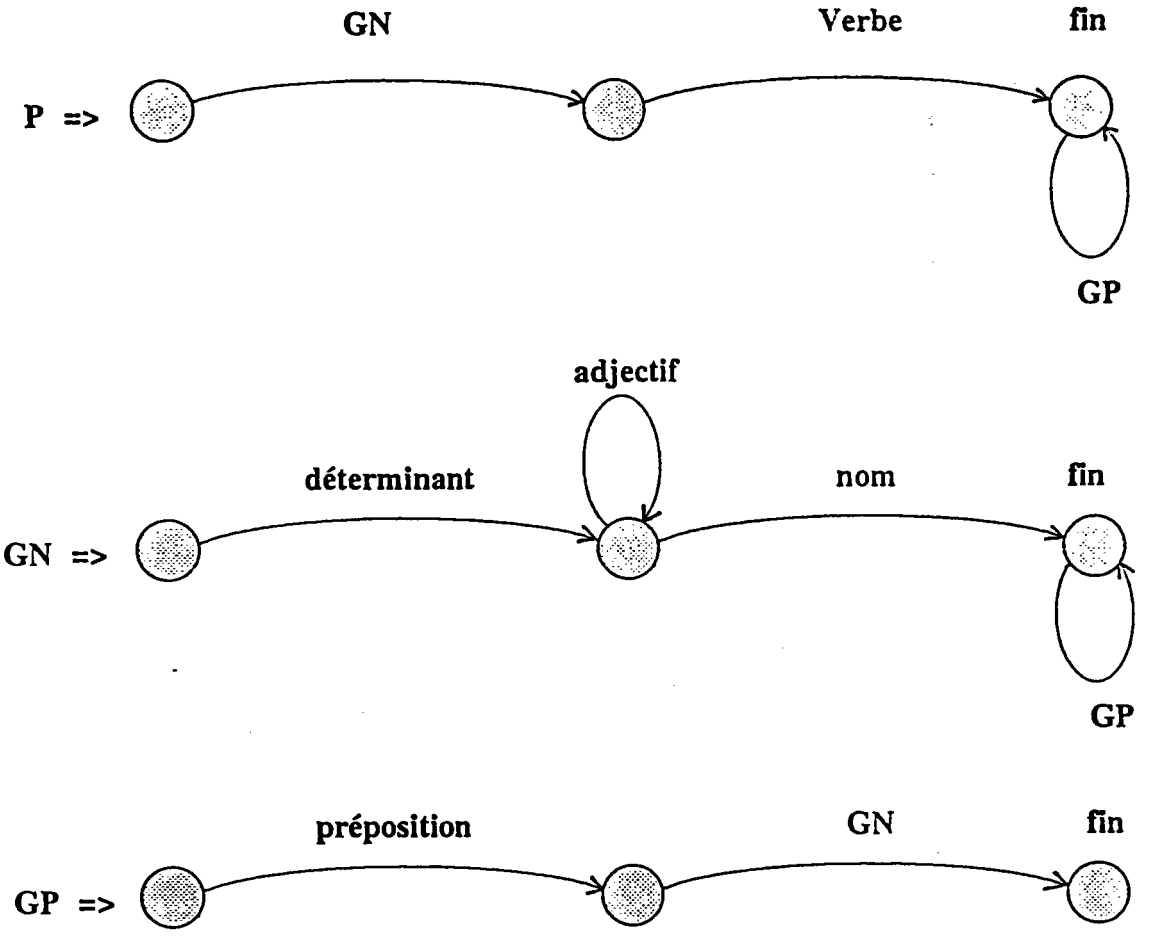

L'automate ainsi défini accepte la phrase *Le joli petit poisson de la soeur de Frédéric nage dans le grand bocal*". On remarque qu'une analyse produite par une grammaire hors contexte équivalente produirait un arbre moins plat. Cette grammaire aurait dû, dans le cas présent, introduire plusieurs symboles pour tenir compte de la répétition des adjectifs. Pour la phrase simplifiée *Le joli petit poisson nage dans le bocal*, nous obtiendrons, avec un RTN :

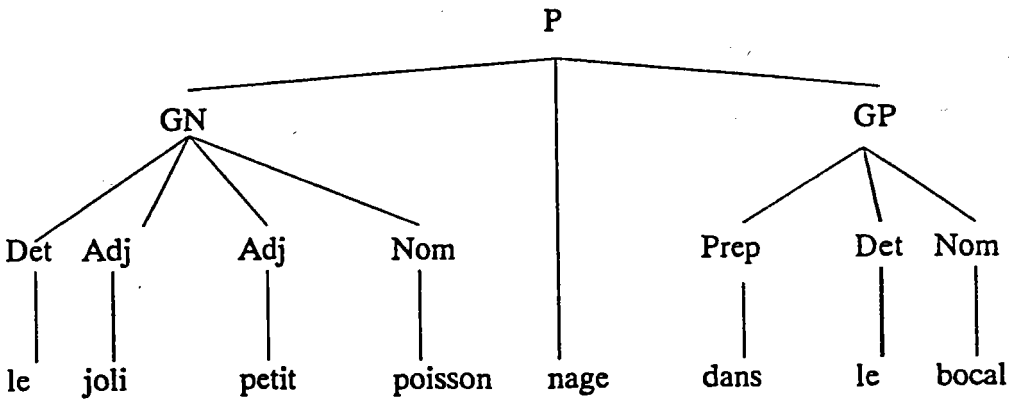

Avec une grammaire indépendante du contexte :

P->GN GV
GN1->GN1+GP
GN->Det GN1
GP->Prép+GN
GN->GN1
GV->Verbe
GN1->Nom
GV->Verbe+GP
GN1->Adj+GN1

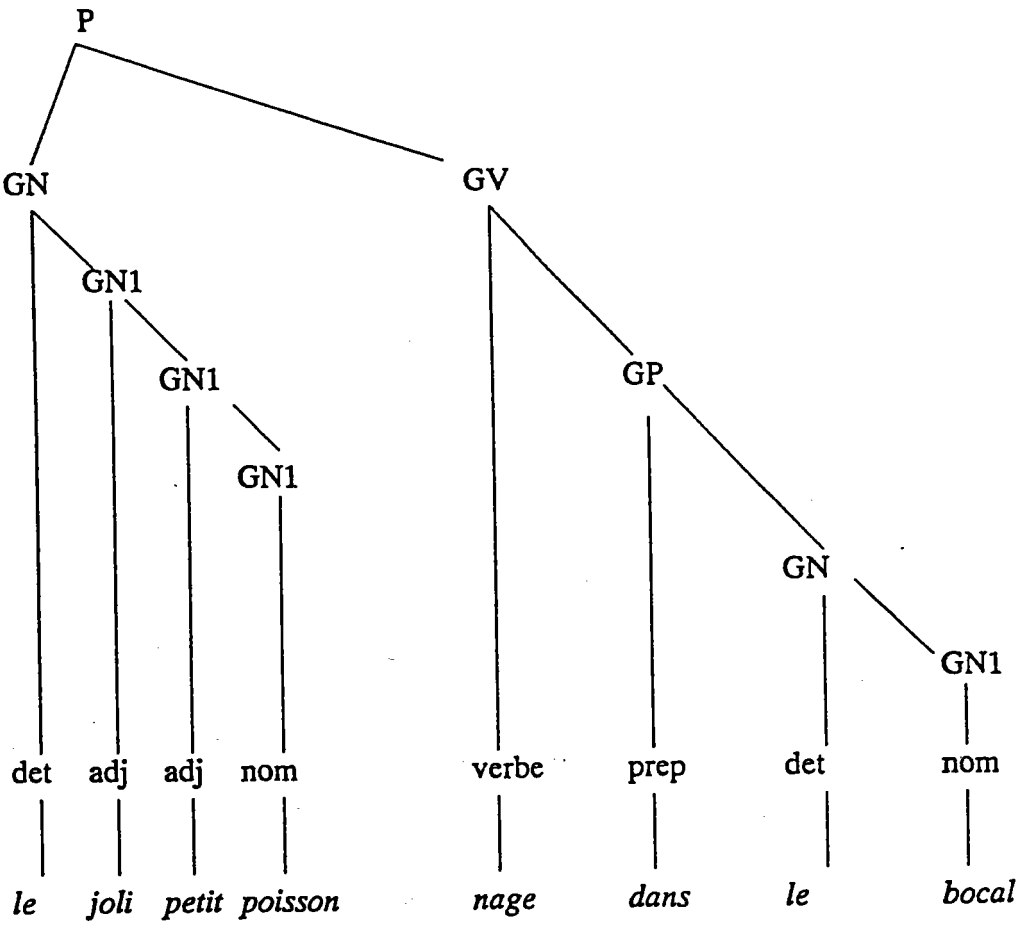

Le mécanisme d'analyse devra être adapté au fonctionnement en parallèle ou au retour en arrière.

Ce type de réseau, fort pratique, ne permet pas de prendre en compte tous les phénomènes des langues naturelles et plus particulièrement certains aspects contextuels. Lorsque le traitement arrive à un noeud, il se poursuit au delà, indépendamment de la façon dont il est arrivé à ce noeud. Il est alors difficile de tester les accords et, plus généralement, de choisir le sens d'un mot par rapport à son contexte.

Si une grammaire à contexte libre peut gérer l'accord (en nombre par exemple), c'est au prix d'une lourdeur rédhibitoire. Les ATNs offrent un formalisme plus approprié pour lever ces limitations.

1.5.4.3 L'ATN ("Augmented Transition Network")

Un certain nombre d'ajouts qui justifient le nom de ces réseaux (réseau de transitions augmenté) va permettre d'intégrer des propriétés des grammaires transformationnelles.

- On peut associer aux arcs des tests à satisfaire pour pouvoir les emprunter. Il faut ajouter à ces conditions, l'appartenance à une classe syntaxique ou sémantique particulière.
ex : on impose que les catégories **Nom** et **Article** soient du même genre.

- On peut spécifier des actions à entreprendre dans le cas où l'arc est emprunté. Ces actions servent à construire des descriptions partielles des segments analysés.
ex : conserver une information qui sera réutilisée par la suite.

- On détermine un ensemble de registres qui contiendront ces descriptions ainsi que des indicateurs qui pourront être testés par des conditions liées à d'autres arcs. Ils sont gérés récursivement et assurent les liens entre les différents sous-réseaux du réseau global.

Nous ne ferons que citer le modèle de J. THORNE[1] qui n'utilise pas de registres, dont les conditions ne portent que sur des tests d'accord et dont les actions se limitent à l'insertion de marqueurs et à l'étiquetage de constituants.

En y ajoutant la possibilité d'une manipulation symbolique, D. BOBROW et B. FRASER[2] ont donné au modèle la puissance d'une machine de TURING générale.
Dans ces systèmes, les structures des données auxquelles s'appliquent les conditions et les actions doivent être écrites dans le langage de programmation utilisé, ce qui limite l'efficacité du concepteur linguiste.
Les travaux de W. WOODS ont conduit à une réalisation plus complète grâce à une utilisation poussée de la notion de registre. Il introduit un nouveau type d'arc : l'arc **Envoi**, dont l'état initial est un état final du réseau et qui n'a pas d'état final. A chaque réseau est associé un ensemble de registres (un attribut et sa valeur) qui précisent les attributs et les rôles attachés à l'ensemble engendré.

Soit un réseau pour la représentation d'un groupe nominal simple dans lequel les formes pronom, déterminant, adjectif et nom sont autorisées.

GN :

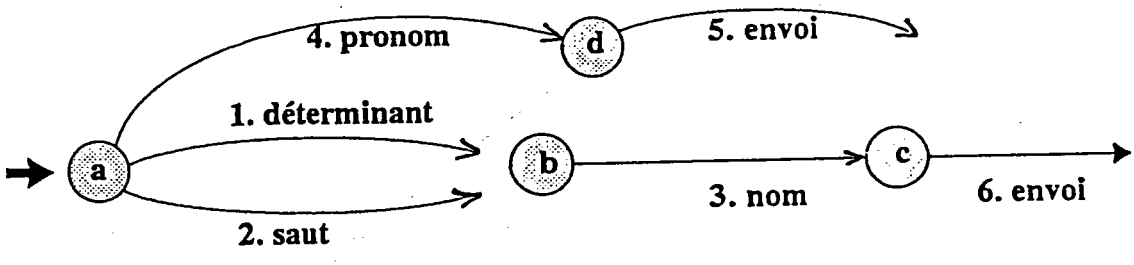

(1) J. THORNE, P. BRATLEY, H. DEWAR : "The Syntactic Analysis of English by Machine" in *Machine Intelligence*, 3, Michie, American Elsevier, New York, 1968
(2) D. BOBROW, B. FRASER : "An Augmented State Transition Network Analysis Procedure", *Actes 1er IJCAI*, Washington DC, pp. 557-567, 1969

L'arc saut ne possède pas de contraintes et permet d'exécuter des actions sous certaines conditions, indépendamment du mot analysé.
Le registre associé au réseau est NOMBRE. On indique alors son domaine de variation NOMBRE(singulier, pluriel).

On associe aux arcs les conditions et les actions suivantes :

-> assigne une valeur à un attribut
* représente un registre spécial qui contient le mot lu ou, lorsqu'on fait appel à un sous-réseau, le résultat produit par ce sous-réseau.

Arc1 : Condition : 0
Action : Nombre <--- Nombre de (*)

Arc3 : Condition : Nombre = 0 ou Nombre = Nombre de (*)
Action : Nombre <--- Nombre de (*)

Arc4 : Condition : 0
Action : Nombre <--- Nombre de (*)

Quand on emprunte l'arc 1, on stocke dans le registre NOMBRE du réseau le nombre correspondant au déterminant.
Pour emprunter l'arc 3, il faudra que le registre soit vide (c'est le cas lorsque l'on est passé par l'arc 2, autrement dit, lorsque le nom n'a pas de déterminant), ou, s'il a une valeur, qu'elle soit identique à celle du nom.

Pour analyser correctement les constituants discontinus (Combien cet homme possède-t-il de voitures ?), il faut pouvoir transmettre des informations d'un noeud à ses descendants. Ceci peut être réalisé par trois méthodes :

- *La communication explicite* : on recopie dans des registres de noeuds descendants les informations du noeud père qui pourraient être utilisées ou reportées sur un autre noeud descendant. Il faut alors vider le registre lorsqu'il est utilisé et ajouter à l'arc une action qui teste si des informations ont été transmises sans avoir été exploitées. Le registre correspondant du réseau appelant doit alors être vidé.
- *la recherche par contexte* : La technique, plus complexe, consiste à consulter les registres liés aux noeuds ascendants du noeud traité, en cas de nécessité seulement, pour rechercher un constituant de type voulu qui semble manquer dans la phrase analysée.
- *les registres globaux* : On ne remplit qu'un seul registre, au niveau général de la phrase. Un arc peut remplir le registre avec un constituant qu'il n'utilise pas , un autre arc pourra ensuite récupérer l'information, pour un constituant manquant.

Pour le fonctionnement des ATNs, la manipulation des registres s'accommode mieux d'une analyse descendante, de la gauche vers la droite.

1.5.4.4 Le CATN ("Cascaded Augmented transition Network")

Créé à l'origine dans un but syntaxique, le modèle qu'a développé W. WOODS[1] introduit une partie sémantique qui n'intervient qu'après l'analyse syntaxique menée par un

---

(1) W. WOODS : "Progress in Natural Language Understanding : an Application to Lunar Geology", *Actes AFIPS*, 42, pp. 441-450, 1973

ATN, pour éliminer les analyses correctes mais dénuées de sens. Le système LUNAR est un système de question-réponse lié à une base de données de la NASA, rassemblant des informations sur les roches rapportées de la lune. L'analyse descendante, effectuée de gauche à droite, existe sous deux versions (la première fonctionne en parallèle, l'autre utilise les retours en arrière).

W. WOODS[1] a cherché par la suite à resserrer l'interaction entre la syntaxe et la sémantique tout en les distinguant nettement. Son modèle de réseau en cascade doit être assimilé à une cascade de deux réseaux.

- le premier réseau accède directement aux mots de la phrase et produit une analyse syntaxique.
- le second réseau accède indirectement aux mots, grâce à un ordre attaché à certains arcs du premier réseau, pour en produire une interprétation sémantique.

1.5.4.5 Le réseau à noeuds procéduraux

Conçu par J.M. PIERREL[2] et utilisé dans le système MYRTILLE (Compréhension de la parole), le réseau à noeuds procéduraux doit son nom au fait que les procédures (conditions et actions) ne sont plus liées aux arcs mais aux noeuds du réseau. Elles servent à contrôler le parcours du réseau en déterminant l'ordre dans lequel il faudra emprunter les branches partant d'un noeud.

1.5.4.6 Exemples

Avec LUNAR de W. WOODS, on peut citer :

PROGRAMMAR de T. WINOGRAD, responsable dans le système SHRDLU de l'analyse procédurale des phrases du dialogue étudié. Très proche d'un ATN, il s'inspire des grammaires systémiques (paragraphe 2.5.3.5) et intègre syntaxe, sémantique et raisonnement.
GUS (Genial Understander System)[3] doit gérer des dialogues homme-machine réalistes. L'exemple concerne un agent de voyage et un client qui désire réserver un billet d'avion.
L'analyse morphologique précède l'analyse syntaxique (RTN) et l'analyse sémantique au cours de laquelle une grammaire génère une structure de rôles convertie par le composant en structure de cas. Lors d'une étape de raisonnement, la question est interprétée et la réponse construite. La phase de génération traduit la réponse en anglais.

La particularité de GUS réside dans la modularité des différents programmes qui ne sont pas déclenchés séquentiellement mais dont le fonctionnement est contrôlé par un agenda qui contient les tâches à effectuer.

SOPHIE[4] enseigne les méthodes de dépannage de circuits électroniques. Le système fonctionne grâce à un ATN fondé sur des catégories lexicales sémantiques. Les aspects pragmatiques peuvent ainsi être pris en compte dès le début de l'analyse.

---

(1) W. WOODS : "Cascaded ATN", *AJCL* 6, pp. 1-12, 1980
(2) J.M. PIERREL : "Etude et mise en oeuvre de contraintes linguistiques en compréhension automatique du discours continu", *Thèse de doctorat ès sciences*, Université de Nancy I, 1981
(3) D. BOBROW, J. KAPLAN, D. NORMAN, H. THOMPSON, T. WINOGRAD : "GUS : a Frame-driven Dialog System", *Artificial Intelligence*, 8, pp. 155-173, 1977
(4) J. BROWN, R. BURTON, A.G. BELL : "SOPHIE : a Step toward a Reactive Environment", *International Journal of Man Machine Studies*, 7, pp. 675- 696, 1975

SPEECHLIS[1] est issu de LUNAR. Il traite les entrées vocales en utilisant les ATNs. Sa grammaire est importante (448 états, 881 arcs et 280 actions) mais le système est étroitement lié au domaine.

W. WOODS[2] souligne l'intérêt des ATNs, dans la perspective d'une généralisation, si l'on considère ces réseaux comme un automate abstrait d'analyse unifiant divers langages de spécification syntaxique. On peut rappeler que les grammaires lexicales fonctionnelles génèrent des langages compatibles avec les ATNs et noter que différents auteurs ont poussé très loin la comparaison avec l'analyseur de M.P. MARCUS[3,4] ou les DCG[5] (Definite Clause Grammar, paragraphe 2.7.7.2). R. BURTON et W. WOODS[6] ont envisagé de compiler la grammaire correspondant à un ATN en un code commun à la grammaire et au mécanisme d'analyse. La vitesse de l'analyseur ainsi conçu est multipliée par 10.

1.5.5 Les analyseurs déterministes

1.5.5.1 Présentation

M.P. MARCUS[7] a tenté de résoudre le problème de l'indéterminisme qui n'a pas pour origine, comme on a tendance à l'affirmer, l'ambiguïté inhérente à la langue, mais plutôt notre façon de conduire une analyse. Nous respectons en effet des habitudes sans grand fondement.

- analyse immédiate et complète des mots lus de gauche à droite
- niveaux d'analyse distincts
- choix a priori des points de reprise

Les analyseurs déterministes apportent des innovations destinées à minimiser les ambiguïtés artificielles.

- Il est possible de stopper une analyse lorsqu'une ambiguïté est rencontrée. Comme avec les ATNs, on conserve les informations obtenues afin de lever l'ambiguïté au moment opportun, de façon plus appropriée.

- Les différents aspects d'un texte peuvent interférer.

- Pour lever des ambiguïtés, ces analyseurs examinent les mots du contexte immédiat.

---

(1) W. WOODS : SPEECHLIS : "An Experimental Prototype for Speech Understanding Research", *IEEE Transactions on Acoustics, Speech and Signal Processing*, 23, 1, pp. 2-10, 1975

(2) W. WOODS : "Generalisations of ATN Grammars", in *Research in Natural Language Understanding*, Woods et Brachman, BBN Report n° 3963, Bolt, Beranek et Newman, Cambridge, Mass., 1978

(3) M.P. MARCUS : *A Theory of Syntactic Recognition for Natural Language*, MIT Press, Cmbridge, Mass., 1980

(4) W. SWARTOUT : "A Comparaison of PARSIFAL with Augmented Transition Networks", *AI memo 462*, MIT, Artificial Intelligence Laboratory, Cambridge, Mass., 1978

(5) F. PEREIRA, D. WARREN : "Definite Clause Grammar for Language Analysis - a Survey of the Formalism and a Comparaison with Augmented Transition Networks", *Artificial Intelligence*, 13, 3, pp. 231-278, 1980

(6) R. BURTON, W. WOODS : "A Compiling System for Augmented Transition Networks", *Actes COLING76*, Ottawa, pp. 65-83, 1976

(7) M.P. MARCUS : *A Theory of Syntactic Recognition for Natural Language*, MIT Press, Cambridge, Mass., 1980

L'analyseur déterministe ignore le parallélisme et le retour en arrière. Il est capable de choisir la bonne voie lorsqu'il y a plusieurs possibilités. Notre façon de comprendre les énoncés s'appuie sur des principes qu'il est intéressant de connaître :
1. - En cas d'ambiguïté, le choix s'oriente vers la solution qui crée le moins de noeuds dans l'arbre d'analyse.

ex : *Le garçon remplit la feuille avec des dessins*

grammaire correspondante (indépendante du contexte) :

P -> GN GV
GN -> ART + NOM
GN -> GN + GP
GP -> PREP + GN
GV -> VERBE + GN
GV -> VERBE + GN + GP

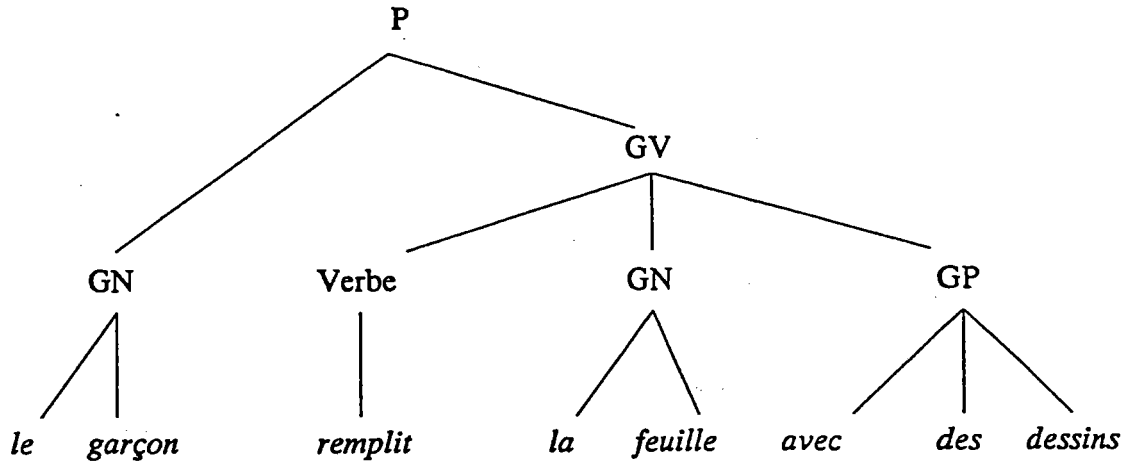

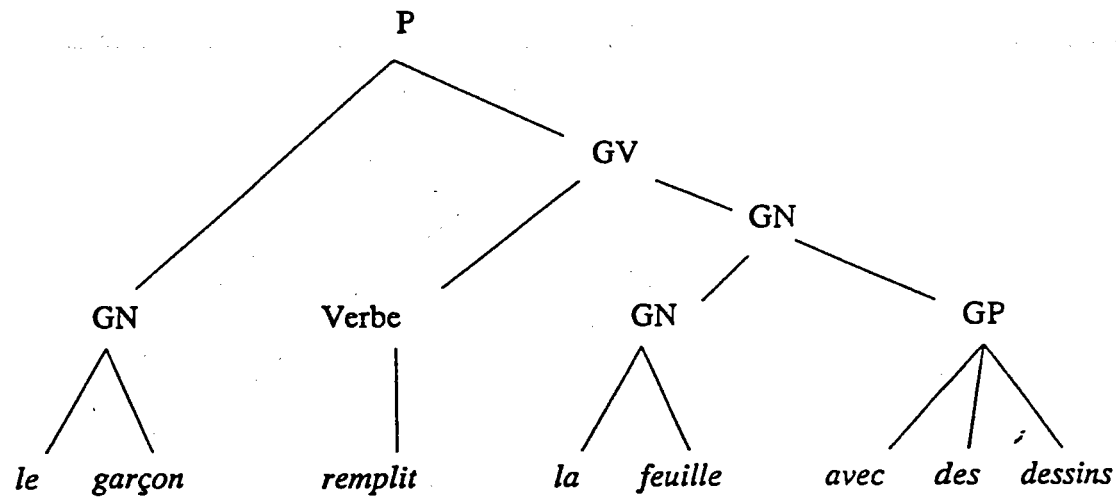

Le choix s'orientera ici vers le premier arbre, (le groupe prépositionnel est attaché au verbe). Le second arbre (le groupe prépositionnel est attaché au nom) possède en effet un noeud de plus.

2. - Il est préférable d'interpréter un constituant en l'associant au constituant qui est en cours de développement, plutôt qu'à un constituant de niveau supérieur.

ex : *Je croyais que tu viendrais hier*

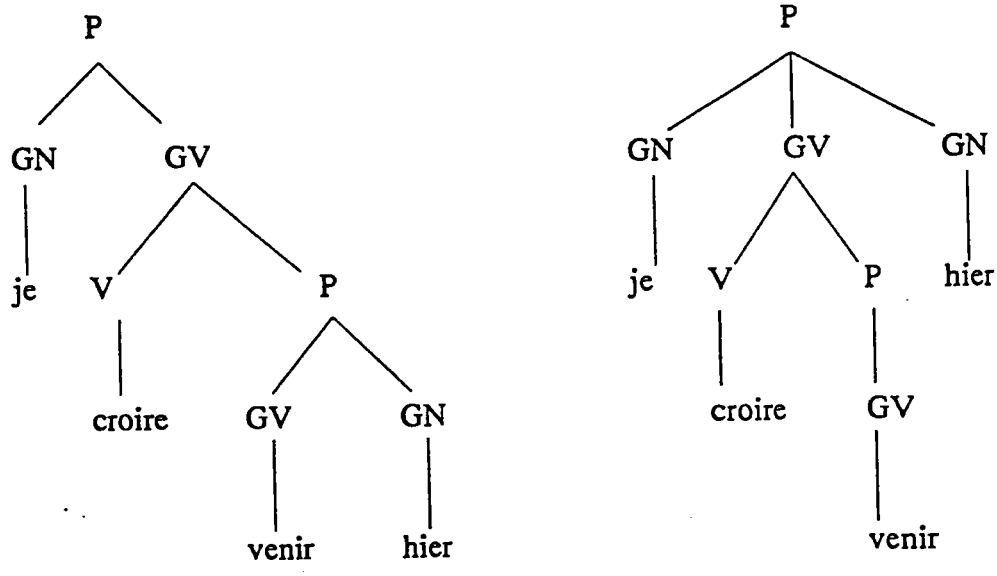

L'automate privilégie la première solution où *hier* représente le moment où la personne vient plutôt que le moment où on le croit.

3. - Les deux principes que nous venons d'évoquer peuvent être contradictoires. On introduit alors la notion de préférence lexicale.

On constate que ces questions ont été abordées, d'une certaine manière, dans le paragraphe précédent, avec les stratégies mises en oeuvre sur les ATNs. La mise en place d'un ordre de passage sur les arcs correspond aux deux premiers principes que nous venons de citer.

Quant au mécanisme qui permet d'examiner les éléments du contexte immédiat dans le but de pouvoir choisir la bonne solution, son champ d'action a été limité à 3 mots vers la droite. Cette limite a été déterminée expérimentalement, dans le sens du meilleur rapport efficacité/complexité. Il faut également préciser que ce "regard en avant" concerne autant les mots et certaines de leurs caractéristiques, que les structures.

1.5.5.2 Exemples

1.5.5.2.1 PARSIFAL

M. MARCUS a conçu PARSIFAL comme un analyseur syntaxique déterministe, n'utilisant ni le parallélisme, ni le retour en arrière, (les structures construites sont définitives et doivent être utilisées dans la représentation finale, les structures temporaires sont impossibles). La couverture linguistique de l'analyseur n'est pas très vaste mais son fonctionnement a validé les principes de l'analyse déterministe et son efficacité.

1.5.5.2.2 ANDI

Cette méthode a été étendue. L'analyseur ANDI (Analyseur Déterministe Intégré)[1,2] doit comprendre des phrases complexes, lever des ambiguïtés lexicales, sémantiques et, dans une moindre mesure, de structures.
Voisin de l'analyseur de M. MARCUS, il s'en écarte cependant sur un point, en intégrant la syntaxe et la sémantique. Il génère en effet "simultanément la structure syntaxique de la phrase et sa représentation sémantique"[3].

Si les analyseurs déterministes apportent de réels avantages :

- leur architecture informatique permet d'éviter les ambiguïtés artificielles dues aux mécanismes d'analyse.
- ils sont plus efficaces que les analyseurs non déterministes, qui perdent beaucoup de temps à tester des mauvaises hypothèses.
- ils conservent une trace de leur fonctionnement, ce qui permet de retrouver les causes d'un échec de l'analyse. Il est alors envisageable d'effectuer un apprentissage automatique des règles de grammaire.

ils présentent de sérieux inconvénients :

- il faut prévoir toutes les ambiguïtés au niveau des règles pour garantir le déterminisme[4].
- les règles sont spécifiques selon le type d'analyse, montante ou descendante (paragraphe 1.5.3.2.2). Utilisant les deux, l'analyseur déterministe nécessite un plus grand nombre de règles.
- les règles ne doivent pas interférer. Leur mise au point est donc plus délicate, la modularité en souffre.
- le principe du déterminisme est un obstacle au traitement des phrases "labyrinthes" lorsque l'analyse du contexte immédiat est limitée. Il est également difficile, pour un tel mécanisme, de donner plusieurs interprétations d'une phrase ambiguë.

1.5.6 Les analyseurs à mots clés

La particularité de cet analyseur et des suivants est d'associer à des unités des éléments de connaissance utiles pour l'analyse de la phrase. Le traitement est plus souple puisque le contrôle de l'analyse est décentralisé.
Fonctionnant dans des domaines limités et ne traitant aucun problème complexe concernant le langage, ils sont très efficaces pour gérer des dialogues dans des domaines clos.
L'analyseur à mots clés ne comprend que certains mots de la langue qui déclenchent alors des actions spécifiques. Il s'appuie sur un lexique qui rassemble les mots significatifs pour le domaine abordé. Il repère ces mots ou leurs variantes et effectue des actions appropriées.

---

(1) M. RADY : "L'ambiguïté du langage est-elle la source du non-déterminisme des procédures de traitement ?" *Thèse de Doctorat ès Sciences*, Université Pierre et Marie Curie, Paris, 1983
(2) G. SABAH, M. RADY : "A Deterministic Syntactic-semantic Parser to French", *Actes 8ème IJCAI*, Karlsruhe, pp. 707-710, 1983
(3) La structure syntaxique engendrée est un arbre syntagmatique aux noeuds duquel sont attachés des traits. La structure sémantique repose sur une grammaire de cas. On y ajoute des informations pour tenir compte des aspects énonciatifs.
(4) E. CHARNIAK : *Parsing, How To in Automatic Natural Language Parsing*, Sparck-Jones & Wilks, University of Essex, 1982

BASEBALL[1] est un système associé à une base de données concernant les matches du championnat de baseball aux Etats Unis. Il répond aux questions simples, à partir d'un vocabulaire d'une soixantaine de mots classés selon quatorze catégories correspondant à des concepts tels que adversaire, match, équipe...
Le mécanisme est simple, l'analyseur reconnaît des mots et construit la question sous une forme canonique, coïncidant avec la forme de stockage dans la base de données.
exemple emprunté à G. SABAH[2] :
A la question : *combien de matches les Yankees ont-ils joué en mai ?*
correspondra : ((Equipe=*Yankee*) (Mois=*mai)* (Match(Nombre_de)=?))

STUDENT[3] fonctionne comme BASEBALL, pour résoudre des exercices d'algèbre élémentaire. Il traite de plus certaines structures de phrases prédéfinies.

ELIZA[4] simule un psychiatre dans le contexte d'un entretien non directif avec des patients. Il dispose d'un ensemble de mots clés avec des ensembles de structures dans lesquelles ils interviennent. Lorsqu'il reconnaît une forme, il lui associe une forme de phrase à compléter, s'il ne trouve aucun mot clé, il choisit une réponse au hasard.

1.5.7 Les analyseurs conceptuels

Les unités de base sont ici des concepts primitifs, qui doivent pouvoir représenter tous les concepts de la langue, par combinaisons. Appliquant les principes de la dépendance conceptuelle, l'analyseur reconnaît d'abors l'occurrence d'un graphe conceptuel (primitives PTRANS, ATRANS, SPEAK...) et valide ensuite les hypothèses impliquées.

ELI (English Language Interpretor) est une variante améliorée de l'analyseur appartenant au programme MARGIE[5] et fait partie du programme SAM[6] qui simule une compréhension à l'aide de scénarios.
Le principe de base est la prévision qui découle des indications apportées par les mots, les concepts correspondants et les structures conceptuelles déjà construites. Les prévisions concernent des mots, des concepts ou des structures conceptuelles que l'on s'attend à rencontrer dans la phrase.
A chaque mot est lié un ensemble de requêtes : {(Conditions, Actions)}. Quand le mot est traité, les requêtes qui lui sont associées sont activées. Nous limiterons notre description de l'analyseur, qui malgré de nombreuses modifications[7] a finalement été abandonné.

D'autres analyseurs ont été conçus selon les mêmes principes:

---

(1) B. GREEN, A.K. WOLF, N. CHOMSKY, K. LAUGHERY : "BASEBALL : An Automatic Question Answer" in *Computers and Thought*, Feigenbaum & Feldman, Mc Graw-Hill, New York, pp. 207-216, 1960
(2) G. SABAH : *L'intelligence artificielle et le langage.* Vol. n 2, Processus de compréhension, Hermes, Paris, pp. 104-105, 1989
(3) D. BOBROW : "Natural Language Input for a Computer Problem Solving System" in *Semantic Information Processing*, Minsky, MIT Press, Cambridge Ma, 1968
(4) J. WEIZENBAUM : "ELIZA : A Computer Program for the Study of Natural Language Communication between Man and Machine", *CACM*, 9, pp. 26-45, 1966
(5) R. SCHANK, N. GOLDMAN, C. RIEGER, C. RIESBECK : "MARGIE : Memory, Analysis, Response Generation and Inferences in Enhglish", *Actes 3ème IJCAI*, 1972
(6) R. SCHANK : "SAM : A Story Understander", Report n°43, Yale University Press, 1977
(7) A.V. GERSHMAN : "Conceptual Analysis of Noun Groups in English", *Actes 5ème IJCAI*, Cambridge Mass., pp. 132-148, 1977

FRUMP (Fast Reading Understanding and Memory Program)[1] analyse des textes, en utilisant une méthode partielle descendante et en complétant des occurrences de scénarios qui ont été reconnus.

IPP (The Integrated Partial Parser)[2] analyse des textes selon une méthode partielle montante et descendante en complétant les MOPs pertinents qu'il a reconnus.

McMAP[3] analyse des textes, en montant et construit les dépendances conceptuelles de la phrase analysée. Il reconnaît les buts des personnages d'une histoire et les plans qu'ils appliquent pour les atteindre.

1.5.8 Les grammaires logiques

Nous les avons assimilées à des outils au même titre que les ATNs, dans le sens où elles laissent une marge de manœuvre importante à leurs utilisateurs. Dans le contexte de leur utilisation pour l'analyse syntaxique et sémantique, elles servent dans le dernier cas autant à l'analyse qu'à la représentation des connaissances.
Leurs possibilités sont très importantes[4]. Elles mènent à des représentations internes autres que les arbres syntagmatiques. Il est possible, d'autre part, lors de leur écriture, de définir les constructions de ces représentations. Il faut rappeler que leur formalisme obéit à une volonté de mise sous forme informatique en utilisant le langage PROLOG pour la description des règles.

Langage de PROgrammation en LOGique, PROLOG a été conçu en 1972 par A. COLMERAUER. Les premieres étapes de son développement ont été assurées principalement à Edimbourg, avant que les japonais le choisissent pour leur ambitieux projet d'ordinateurs de "5ème Génération".

Un programme PROLOG est une suite de "clauses" qui peuvent être considérées comme une généralisation des règles de réécriture et comme une formule représentant le sens :

GN(X,Y) -> DET(X,Y) NOM(Y,Z) est équivalent à GN -> DET, NOM

ONCLE(X,Z) -> FRERE(X,Y) PERE(Y,Z) X est l'oncle de Z lorsque X est frère de Y, et Y père de Z

Utilisé pour programmer les analyseurs syntaxique et sémantique, ils servent également à représenter les connaissances nécessaires à la compréhension.

Les règles de réécriture ne combinent plus seulement de simples identificateurs, mais des prédicats et des variables, ce qui implique des processus d'unification pour que les variables aient une valeur identique dans toutes les règles.

Des contraintes sur la nature des variables vont permettre de soumettre l'application des règles à certaines conditions.

---

(1) G. DEJONG : *An Overview of the FRUMP System in Strategies for Natural Language Processing*, Lehnert et Ringle, Erlbaum, Hillsdale, N.J., pp. 149-176, 1982
(2) R. SCHANK, M. LEBOWITZ, L. BIRNBAUM : *An Integrated Understander, American Journal of Computational Linguistics*, 6, 1, pp. 13-30, 1980
(3) M. DYER : *In-Depth Understanding*, MIT Press, Cambridge MA., 1983
(4) Actes du Colloque "Compréhension du langage naturel et programmation en logique", Rennes, sept. 1984, North Holland, 1985

1.5.8.1 Les grammaires de métamorphose. Les DCG (Definite Clause Grammars)

A l'origine de ces grammaires logiques, on trouve les grammaires de métamorphose[1], exécutables par un interpréteur PROLOG. Lorsque la partie gauche d'une règle n'est pas un symbole logique non terminal suivi facultativement de symboles logiques terminaux mais se résume à un seul élément non terminal, nous avons les grammaires à clauses définies (DCG, "Definite Clause Grammars")[2,3].

L'ajout de conditions et d'actions aux règles de ces grammaires les rendent aussi puissantes dans leur formalisme que les ATNs, tout ATN pouvant être transformé en une DCG :
Empruntons l'exemple d'un ATN pour analyser les groupes nominaux élémentaires à D. COULON et D. KAYSER[4] :

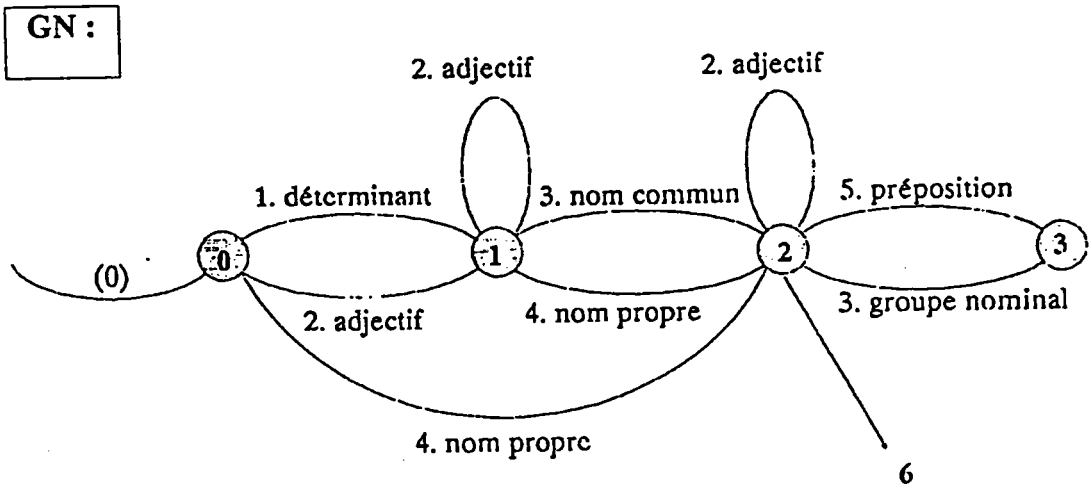

Une décomposition en graphes simples sans circuit donne :

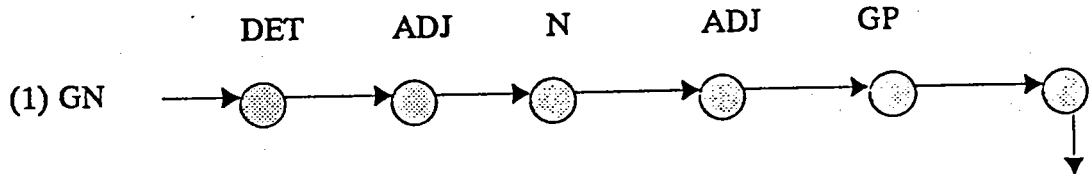

---

(1) A. COLMERAUER : "Les grammaires de métamorphose" in L. BOLC (ed.), *Natural Language Communication with Computers*, Lecture Notes in Computer Science, n°63, Springer Verlag, pp. 133-189, 1978

(2) F. PEREIRA, D. WARREN : "Definite Clause Grammar for Language Analysis - A Survey of the Formalism and a Comparaison with Augmented Transition Networks", *Artificial Intelligence*, 13, 3, pp. 231-278, 1980

(3) D. WARREN, F. PEREIRA : "An Efficient Easely Adaptable System for Interpreting Natural Language Queries", *American Journal of Computational Linguistics*, 8, (3-4), July-dec., 1982

(4) D. COULON, D. KAYSER : "Informatique et langage naturel" in *Technique et science informatiques*, Vol. 5, n 2, p. 117, 1986

(2) DET 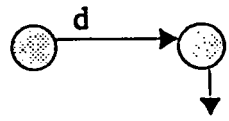

(3) ADJ 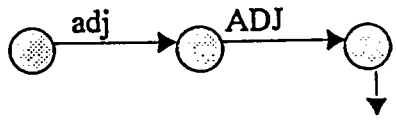

(4) GP 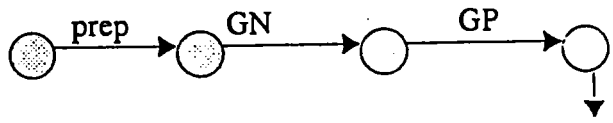

Pour chaque chemin, on écrit une règle PROLOG :
En partie gauche : le prédicat avec, pour argument, la structure correspondante.
En partie droite : les prédicats à tester.

PGN(GN<DET,ADJ1,N,ADJ2,GP) -> PDET(DET), PADJ(ADJ1), PN(N),
PADJ(ADJ2), PGP(GP)

Les prédicats à tester (par ex. PDET(DET)) engendrent de nouvelles structures par unification avec les parties gauches des autres règles.

PDET(DET < d >) -> [d], {déterminant(d)}

Ils servent à tester l'existence de mots terminaux, écrits entre crochets et déclenchent des vérifications, comme la nature du mot, par consultation du lexique, ce qui est indiqué par les accolades. Pour obtenir une traduction complète de l'ATN, il faut retranscrire les actions, ce qui s'obtient en employant des conditions supplémentaires ou des arguments supplémentaires qui permettent alors de stocker des résultats intermédiaires comme les registres des ATNs.

1.5.8.2 Les extensions

Les grammaires d'extrapositions[1,2] introduisent la notion de discontinuité en permettant de noter dans une règle une partie de phrase à laquelle on ne s'intéresse pas.
Nous pouvons mentionner deux autres développements de ces modèles : les grammaires à structures modifiées[3] qui expriment plus clairement les représentations que l'on souhaite engendrer et les grammaires d'arbres et de puzzle[4] qui élaborent des arbres par unification entre les feuilles et les racines.

---

(1) **V. DAHL, H. ABRAMSON** : "On Gapping Grammars", *Actes de la 2ème Logic Programming Conference*, Uppsala University, 1984
(2) **F. PEREIRA** : "Extraposition Grammars", Computational Linguistics, Vol. 7, 1981
(3) **V. DAHL, Mc CORD** : "Traiting Coordination in Logic grammars", *American Journal of Computational Linguistics*, Vol. 9, n2, pp. 69-91, 1983
(4) **P. SABATIER** : "Puzzle Grammars", *Actes du premier Colloque International "Natural Language and Logic Programming"*, Rennes, 1984

1.5.9 Les outils intégrés

Le traitement des ambiguïtés met en valeur la nécessité d'une plus grande intégration des différentes phases de l'analyse. Les informations qui permettent d'opérer les bons choix sont diverses. Les modules de traitement s'enchaînent sans qu'il soit possible d'utiliser au maximum le fait que les résultats des uns peut aider au fonctionnement des autres et inversement.

L'utilisation du langage PROLOG pour formaliser toutes ces phases (paragraphe 1.5.8) est une première tentative.

La technique du tableau noir (paragraphe 1.5.3.2.1) préfigure une intégration plus poussée. Chaque module utilise les informations qui lui sont utiles et stocke celles qu'il trouve[1].
Le principe de l'interaction des différents programmes qui fonctionnent en parallèle (parallélisme réel ou simulé) devrait être développé avec l'apparition des langages objets[2]. L'interaction des niveaux est facilitée par un mécanisme de propagation de messages associé à une décentralisation du contrôle[3].

Il est probable que la réalisation d'une intégration optimale sera liée aux futurs ordinateurs parallèles[4].

1.5.10 Le traitement des erreurs

Le traitement automatique des langues se heurte parfois :

- à des erreurs d'orthographe (niveau lexical)
- à des structures incorrectes (niveau syntaxique)
- à des représentations contradictoires, incomplètes ou à des erreurs conceptuelles (niveau sémantique)
- à des ambiguïtés ou des imprécisions (niveau pragmatique)

Certains auteurs ont proposé une typologie des "non-attendus", en distinguant les erreurs de compétence (manque de connaissances) et les erreurs de performance (manque d'attention, problème matériel, ...)[5].

Nous les passerons rapidement en revue en distinguant plutôt les niveaux (lexical, syntaxique, sémantique et pragmatique), tout en reconnaissant que les erreurs ne sont pas toujours repérées au niveau où elles interviennent, et peuvent être corrigées grâce à des informations d'un autre niveau. Nous citerons à chaque fois les méthodes de correction envisageables, sachant que certains systèmes préfèrent ignorer les erreurs et continuer le traitement, d'autres diffèrent l'interprétation, recommencent l'analyse, étudient le contexte immédiat ou demandent de l'aide en fonctionnement interactif.

---

(1) **L. ERMAN, F. HAYES-ROTH, V. LESSER, R. REDDY** : "The Hearsay II Speech Understanding System", *Computing Surveys*, 12(2), 1980

(2) **J. FERBER** : "Les langages objets : une affaire de messages", *Revue Microsystèmes*, avril 1985, pp. 152-159, 1985

(3) **K. De SMEDT** : "Using Object-oriented Knowledge Representation Techniques in Morphology and Syntax Programming", *Actes ECAI*, pp. 181- 184, sept. 1984

(4) **D. WALTZ, J. POLLACK** : "Massively Parallel Parsing : A Strongly Interactive Model of Natural Language Interpretation", *Cognitive Science*, 9(1), pp. 51-74, 1985

(5) **J. VERONIS** : "Le traitement de l'erreur dans le dialogue homme- machine en langage naturel, application à l'enseignement assisté de la géométrie", *Thèse de l'Université d'Aix-Marseille*, 1988

1.5.10.1 Plan lexical

1.5.10.1.1 Types d'erreur

- Les erreurs concernent l'écriture du mot et s'appliquent à une lettre ou à un groupe de lettres. Ce sont les fautes classiques de substitution (*povr* au lieu de *pour*), d'insertion (*duees* au lieu de *dues*), de suppression (*exempe* au lieu d'*exemple*), d'erreur de signe diacritique (*facon* au lieu de *façon*), d'interversions (*immédait* au lieu d'*immédiat*), de redoublements (*constitutition* au lieu de *constitution*).
- A ces fautes de frappe, il faut ajouter les fautes grammaticales de l'utilisateur qui ignore l'orthographe du mot et propose une écriture phonétique (*laupain* au lieu de *lopin*) et les fautes de flexion (genre, nombre, conjugaison).
- Citons enfin les mots que le système ne peut analyser parce qu'ils ne sont pas dans le lexique dont il dispose (le domaine est ouvert et le mot n'a pas été prévu, le domaine est fermé, le mot est absent ou il s'agit d'un néologisme, le problème des noms propres étant, dans ce cadre, assez complexe).

1.5.10.1.2 Techniques de correction

Deux études sur la répartition statistique des fautes ont été réalisées, la première par F. DAMERAU[1], la seconde par J.J. POLLOCK et A. ZAMORA[2]. L'une indique que 80% des mots erronés sont des erreurs uniques dans le mot. Pour l'autre, 90% des mots erronés contiennent une seule erreur. On peut cependant reprocher à ces travaux de ne pas être très représentatifs, et aux résultats, de ne pas être précis. En effet, si l'on replace ces résultats dans leur contexte, on constate que les buts étaient différents :

- indexation et recherche de documents par mots clés, pour F. DAMERAU, avec un matériel de stockage sur ruban papier et les risques que cela implique.
- analyse de textes scientifiques (25.000.000 mots) malheureusement saisis par des professionnels.

Ces données permettront cependant d'élaborer des méthodes de correction.

- méthodes fondées sur la distribution des graphèmes : Lorsqu'un mot n'est pas reconnu, elles proposent une correction en utilisant les probabilités d'apparition de toutes les paires et triades de graphèmes de la langue traitée[3,4].
Elles n'ont pas besoin de dictionnaires, concernent tous les domaines mais ne sont efficaces que pour les erreurs de substitution. On les utilise surtout pour la relecture des documents saisis par lecture optique.
- méthodes de recherche dans les dictionnaires : Elles sont mieux adaptées aux fautes d'insertion, de suppression et d'inversion.
Les dictionnaires envisagés doivent répondre à deux exigences :
- retrouver un mot correctement orthographié, le plus rapidement possible et avec une consultation minimale.

---

(1) F. DAMERAU : "A Technique for Computer Detection and Correction of Spelling Errors", *Journal des ACM*, 7, 3, pp. 171-176, 1964

(2) J.J. POLLOCK, A. ZAMORA : "Automatic Spelling Correction in Scientific and Scholary Texts", *Communications ACM*, 27, 4, pp. 358- 368, 1984

(3) E.M. RISEMAN, R.W. EHRICH : "Contextual Word Recognition Using Binary Digrams", *I.E.E.E. Transactions on Computers*, 20, 4, pp. 397- 403, 1971

(4) E.M. RISEMAN, A.R. HANSON : "A Contextual Post-processing for Error Correction Using Binary n-gramms", *I.E.E.E. Transactions on Computers*, 23, 5, pp. 480-493, 1974

- repérer l'absence d'un mot mal orthographié et proposer des solutions de substitutions. Le meilleur moyen de concilier ces nécessités contradictoires est de concevoir une structure appropriée du lexique[1]. On détermine une structure adaptée à une recherche exacte rapide (paragraphe 1.5.2.1) et on lui associe un sytème de génération automatique des variantes possibles pour chaque mot que l'on recherche séquentiellement.
Pour la substitution, l'insertion, la suppression et l'interversion, en considérant un mot de longueur **l** et un alphabet de **n** lettres, on engendre **l-1** mots voisins par inversion de deux lettres consécutives, **(n-1)*l** par substitution, **n*(l+1)** par inversion d'une lettre et **l** par suppression d'une lettre. Pour traiter 90% des fautes (une erreur par mot), on aboutit à **l(2n+1)+n-1** candidats. Avec un mot de 7 lettres et un alphabet de 32 lettres on obtiendrait 486 possibilités, ce qui représente finalement une certaine lourdeur en temps d'accès mémoire. Le programme SPELL[2] utilise cette technique qu'il est possible d'améliorer en testant les invraisemblances et en limitant ainsi les recherches[3].

- Il existe une autre méthode : on partitionne le lexique et on ne compare ainsi le mot erroné qu'avec un sous-ensemble du lexique, en espérant trouver rapidement sa classe d'équivalence en se basant sur la longueur du mot[4] ou les caractères à l'initiale du mot[5]. Les classes d'équivalence sous-tendent la notion de "clé de similarité" qui correspond à un code calculé à partir des lettres du mot. Des chaînes voisines pourront avoir une clé identique et définir ainsi une classe d'équivalence. La clé permet alors d'appeler tous les candidats au remplacement. Notons que cette clé, pour être efficace, doit tenir compte de plusieurs informations. Construite uniquement sur la longueur du mot, elle regrouperait des chaînes trop différentes.

Le système de J.J. POLLOCK et A. ZAMORA utilise deux clés. (*la clé squelette* et *la clé d'omission*). F. DEBILI[6] propose une clé construite en reprenant dans l'ordre alphabétique toutes les lettres constituant le mot. L'avantage des clés réside dans le fait que leur longueur facilite leur gestion et l'accès aux mémoires de stockage.

- Méthodes phonologiques : Peu de systèmes traitent ces erreurs de substitution d'un graphème à un graphème de même prononciation (*meigre, mègre, maigre...*), d'inversion ou de suppression d'un graphème muet (*éthymologie - étymologie...*).
PIAF[7] construit toutes les formes phonétiques d'un mot analysé et génère les formes orthographiques possibles à partir d'un transducteur d'états finis. VORTEX[8] traite les fautes typographiques et les fautes orthographiques. Après avoir transcrit le mot phonétiquement, il génère toutes les fautes possibles à partir d'un codeur orthographique (modèle des fautes les plus fréquentes), d'un canal typographique (modèle des fautes typographiques) et d'un canal de permutation (modèle des erreurs de permutation).

---

(1) **P.A.V. HALL, G.R. DOWLING** : "Approximate String Matching", *Computers Surveys*, 12, 4, 1980
(2) **J.L. PETERSON** : "Computers Programs for Detecting and Correcting Spelling Errors", *Communications ACM*, 23, 12, pp. 676-687, 1980
(3) **J. ULLMAN** : "A Binary n-gram Technique for Automatic Correction of Substitution, Deletion, Insertion and Reversal Errors in Words", *Computer Journal*, 20, 2, pp. 141-147, 1977
(4) **A.J. SZANZER** : "Error Correcting Methods in Natural Language Processing", *Information Processing*, 68, IFIP, pp. 1412-1416, 1969
(5) **H.L. MORGAN** : "Spelling Correction in System Programs", *Communications ACM*, 18, 1, pp. 54-64, 1970
(6) **F. DEBILI** : "Les fonctionnalités linguistiques exigibles d'un système de documentation automatique", *Congrès informatique et Droit, ADIJ*, Strasbourg, 1987
(7) **J. COURTIN** : "Algorithmes pour le traitement interactif des langues naturelles", *Thèse de Doctorat ès Sciences*, Grenoble, 1977
(8) **G. PERENNOU, P. DAUBEZE, F. LAHENS** : "La vérification et la correction automatique de textes : le système VORTEX", *Technique et Science informatiques*, 5, 4, pp. 285-305, 1986

E. LAPORTE propose un système qui part d'une transcription phonétique du mot testé et la compare avec un dictionnaire de formes phonétiques générées automatiquement à partir du DELAS, le dictionnaire du LADL (paragraphe 2.5.3.6.3).

Les méthodes évoquées ci-dessus permettent de trouver un mot voisin du mot que l'on recherche dans le lexique des mots attestés. Un autre point de vue consiste à proposer des caractéristiques potentielles à propos d'un mot qui existe mais ne figure pas dans le dictionnaire. Les techniques proposées par J. VERGNE[1] et P. PAGES[2] s'appuient sur l'étude du système dérivationnel et la décomposition du mot (racines et affixes) afin d'en déduire des informations morphosyntaxiques et sémantiques[3].

1.5.10.2 Plan syntaxique

1.5.10.2.1 Types d'erreur

Les fautes rencontrées concernent les relations qu'entretiennent entre eux les mots de la phrase : on peut noter :

- l'oubli : *il n'y a pas d'accord ce point / il n'y a pas d'accord sur ce point*
- le redoublement : *la décomposition du du mot / la décomposition du mot*
- la permutation : *ainsi de que nombreux signes / ainsi que de nombreux signes*
- les erreurs de construction : *je vais au dentiste / je vais chez le dentiste, je m'en rappelle / je me le rappelle*
- les fautes d'accord : *j'irais / j'irai, les chat / les chats, vous parler / vous parlez*

1.5.10.2.2 Techniques de correction

Il existe plusieurs voies pour traiter les erreurs de construction :

- augmenter la grammaire : Certaines fautes sont si fréquentes qu'on peut les assimiler à des structures acceptables en les réunissant dans une "grammaire de fautes".

- assouplir les contraintes : L'application des règles de grammaire est soumise à certaines contraintes. Certains auteurs[4] ont montré qu'il était possible, dans certains cas, de négliger des augmentations dans un ATN pour relancer l'analyse bloquée sur un échec.

- réduire le champ de l'analyse : Analyser une phrase revient à lui faire correspondre un sous-ensemble de règles. On peut imaginer des procédures qui limiteraient cette correspondance à certaines règles[5] ou à certains mots.

---

(1) J. VERGNE : "Une méthode structurelle de reconnaissance des formes pour l'analyse morpho-syntaxique du français sans dictionnaire ; Etude de faisabilité sur les groupes nominaux complexes", *Congrès RF-IA*, AFCET-INRIA, 1987

(2) P. PAGES : "Analyse morphologique automatique du français, extraction des verbes et mise en valeur morpho-sémantique de la dérivation", *Thèse de 3ème cycle*, INALCO, Paris III, 1984

(3) M. PONAMALE : "Compréhension automatique de mots inconnus à partir de leur morphologie", *Mémoire de l'IIE*, CNAM, 1987

(4) R. WEISCHEDEL, J. BLACK : "Responding to Potentially Unparseable Sentences", *American Journal of Computational Linguistics*, 6, pp. 26- 45, 1980

(5) P. HAYES, G. MOURADIAN : "Flexible Parsing", *American Journal of Computational Linguistics*, 7, 4, pp. 232-241, 1983

- réduire l'analyse au plan sémantique et ignorer les erreurs syntaxiques.

Ces différentes voies ont été reprises en partie par C. FOUQUERE[1] qui pour analyser une phrase mal construite, propose de réaliser une analyse non linéaire capable de repérer des zones correctes (ilôts de confiance) et d'extraire des informations pour interpréter les zones qui ne peuvent être interprétées.

Basé sur les ATNs, un ensemble d'analyses partielles extrait les structures sûres. Il faut ensuite supprimer les points d'embarras en utilisant les méthodes citées plus haut pour rassembler les analyses partielles.

Pour raccourcir le temps de traitement, C. FOUQUERE a construit un formalisme "d'analyse tolérante" utilisant une grammaire dite "à configuration minimale". Les analyses partielles engendrent des arbres que des procédures tentent de relier lorsque l'analyse est bloquée.

En ce qui concerne les règles d'accord, les systèmes limités peuvent s'offrir le luxe de les ignorer.
Il est évident que les informations liées au genre, au nombre, à la personne, au mode et au temps sont d'une importance capitale. Les fautes qui sont repérées concernent essentiellement des paires de mot, le déterminant ou l'adjectif avec un nom, le sujet et le verbe.
Plusieurs critères sont alors indispensables pour déterminer la bonne correction qui, en général, répond à l'heuristique bien connue selon laquelle "la bonne correction" implique le minimum de changements.

1.5.10.3 Plan sémantique

1.5.10.3.1 Les types d'erreur

Même à l'intérieur d'un domaine limité, les erreurs sont difficilement repérables.

- les erreurs conceptuelles reflètent une conception erronée de l'auteur dans ses suppositions ou dans son raisonnement.
- les erreurs pragmatiques concernent les messages corrects que l'on émet, dans une situation donnée, de façon inappropriée.

1.5.10.3.2 Techniques de correction

Dans l'état actuel des recherches, on préfère opter pour une limitation claire des systèmes, et une transparence pour l'utilisateur qui pourra lui-même en contrôler les possibilités. Les travaux réalisés jusqu'à maintenant concernent surtout les systèmes de questions-réponses[2]

Nous dirons, en résumé, que si la correction automatique des erreurs lexicales est une pratique courante et agrémente d'une façon plus ou moins efficace les logiciels actuels de traitement de texte, la correction des erreurs syntaxiques et sémantiques en est au stade des balbutiements et ne pourra progresser qu'avec le développement des recherches sur la représentation des connaissances et les mécanismes de compréhension.

---

(1) C. FOUQUERE : "Systèmes d'analyse tolérante du langage naturel", *Thèse de l'Université de Paris-Nord*, 1988
(2) J.B. BERTHELIN, G. SABAH : "Degrés qualitatifs d'acceptabilité en informatique linguistique", *Actes Cognita, AFCET-ARC-CESTA*, Paris, pp. 269-275, 1985

1.6 Conclusion

Nous avons abordé les relations du langage avec la linguistique et l'informatique à travers les modèles de la langue et les outils d'analyse. Cette présentation simplifiée et réduite à l'analyse illustre la complexité d'un domaine dont la Traduction Automatique et la Traduction Assistée par Ordinateur ne sont que des exemples d'application.

Le traitement automatique des langues naturelles couvre en effet de nombreux autres domaines, parmi lesquels :

- L'interrogation de banques de données : Elle est au coeur des recherches depuis plus de 25 ans. Les systèmes concernés traduisent une requête exprimée en langue naturelle sous la forme d'un langage d'interrogation. L'interrogation de banques de données déductives ne se contente pas de chercher des informations explicites, elle implique une certaine déduction.
- *Dans une approche fondée sur la logique*, les informations contenues dans la banque sont les axiomes d'un système logique au sein duquel on applique les règles d'inférences de la logique classique. PROLOG est un outil privilégié dans le sens où il permet de représenter les informations dans la base, les règles de déduction, les règles de grammaire et la génération des réponses.
- *Dans une approche fondée sur les réseaux sémantiques*, on utilise par défaut les processus de déduction de la logique de premier ordre, en l'absence de moyens plus efficaces[1].
- La génération de texte : Bien que le problème soit vital, il a toujours été masqué par les techniques de représentation des connaissances. A la méthode fill-in-the-blanks, qui consiste à remplir des phrases stéréotypées (ELIZA[2]) par des paramètres fournis en cours de traitement par différents modules, on peut ajouter les travaux de N. GOLDMAN[3] visant à générer du texte dans le cadre du système de paraphrasage de R. SCHANK, les recherches de J. SLOCUM[4] et de R. SIMMONS[5] à partir des réseaux sémantiques, celles de R. GRISHMAN[6] à partir du calcul des prédicats, de L. DANLOS[7] et de N. SIMONIN[8]. Citons également les générateurs liés aux systèmes de Traduction Automatique.
- La documentation automatique : Les quantités de texte peuvent être énormes, aussi ne travaille-t-on pas sur le texte lui-même. On préfère utiliser un système d'indexage géré par des fonctions booléennes appliquées à des mots clés. J.M. DAVID[9] propose des techniques plus complexes d'accès aux documents. L'Intelligence Artificielle n'a cependant rien apporté de plus, pour l'instant sur un plan opérationnel.

---

(1) G. HENDRIX : "Encoding Knowledge in Partitioned Networks" in N. FINDLER (ed.) *Associative Networks : Representation and Use of Knowledge by Computer*, Academic Press, New York, 1979

(2) J. WEIZENBAUM : "ELIZA, a Computer Program for the Study of Natural Language Communication between Man and Machine", *Communications ACM*, 9(1), pp. 36-45, 1966

(3) N. GOLDMAN : "Conceptual Generation" in R. SCHANK (ed.) *Conceptual Information Processing*, North Holland, pp. 289-371, 1975

(4) J. SLOCUM : "Generating a Verbal Response" in D. WALKER (ed.) *Understanding Spoken Language*, North Holland, pp. 375-380, 1975

(5) R. SIMMONS, J. SLOCUM : "Generating English Discourse from Semantic Networks", *Communications ACM*, 15(10), pp. 891-905, 1972

(6) R. GRISHMAN : "Response Generation in Question Answering Systems", *Proc. of 17th Am. for Computational Linguistics*, La Jolla, pp. 99-101, 1979

(7) L. DANLOS : "Génération automatique de textes en langue naturelle", Paris, Masson, 1985

(8) N. SIMONIN, J.M. LANCEL : "Essai de modélisation de l'expertise en rédaction de textes", *Actes Cognitiva*, Paris, pp. 263-268, 1985

(9) J.M. DAVID : "Simulation de l'activité d'un documentaliste", *Actes du congrès AFCET Informatique*, Nancy, pp. 362-371, 1980

- Le traitement de texte : Les progrès de la bureautique encouragent le développement d'outils linguistiques pouvant manipuler les textes à des niveaux morpho-lexicaux ou même syntaxiques mais de façon très rudimentaire (dictionnaires et correcteurs, aides à la rédaction).
- La robotique : L'application concerne la communication avec les robots (dialogue homme-machine).
- L'Enseignement Assisté par Ordinateur (E.A.O.) : Le contexte de l'E.A.O. se prête à la construction de dialogues de bonne qualité car la situation pédagogique restreint le champ sémantique et le système ne requiert pas de grandes masses de connaissances. M. PEUCHOT[1], D. COULON et D. KAYSER[2] ont construit des systèmes assez rudimentaires qui donnent de bons résultats. Des systèmes plus évolués, comme SOPHIE[3] et GUIDON[4] incorporent des analyseurs du langage naturel et étendent la marge de liberté de l'étudiant. Nous pensons qu'il serait intéressant d'appliquer ces techniques non pas seulement à la forme mais aussi au contenu des didacticiels, qui auraient tout à y gagner, en ce qui concerne le domaine des langues, bien entendu. En annexe, nous donnerons un exemple de ce qu'il est possible de proposer dans ce cadre, comme sous-produit de notre analyseur.
- Résolution d'énoncés en langage naturel : La sémantique réduite permet d'obtenir de très bons résultats. De nombreuses applications ont suivi le programme STUDENT[5], dont celle de M. ROUSSEAU[6]
- La traduction automatique : On peut considérer que ce domaine constitue l'exemple des difficultés qui ont été mal mesurées en ce qui concerne le traitement automatique des langues naturelles.Y. BAR-HILLEL[7] avait déjà subordonné la bonne qualité d'une traduction à la représentation de grandes quantités de connaissances. Des résultats satisfaisants ont pu être obtenus en utilisant au maximum les règles syntaxiques ou en incorporant localement des traitements sémantiques.

On constate que la majorité des thèmes évoqués concernent surtout l'Intelligence Artificielle. La rapidité et l'ampleur de son développement éclipsent quelque peu la T.A. et la T.A.O. qui n'occupent plus le devant de la scène du Traitement Automatique des Langues Naturelles. La raison nous paraît fort simple : les objectifs de la traduction automatique sont proprement inaccessibles, dans l'état de nos connaissances sur la langue et les résultats ne sont pas à la mesure des investissements consentis. La linguistique a beaucoup gagné dans l'aventure mais les progrès que l'on attend d'elle sont-ils à sa portée ?
Les chagrins diront que le formalisme a ses limites. Les méthodes sont nombreuses, nous venons d'en voir quelques unes, et peut-être inadaptées. N'a-t-on pas cherché à imposer à la langue un formalisme qui lui était complètement extérieur et qui, par conséquent, ne peut pas toujours fonctionner correctement ? Issu des mathématiques (de la logique et de la théorie des graphes), son origine n'est-elle pas malencontreuse ?

---

(1) M. PEUCHOT : "De l'enseignement assisté à la diffusion automatique de l'information", *Zéro-Un Informatique*, mai 1971
(2) D. COULON, D. KAYSER : "Analyse de réponses rédigées en Français courant pour une réalisation d'enseignement programmé", RAIRO, revue bleue, n°2, pp. 61-98, 1972
(3) J. BROWN, A. BELL : SOPHIE, "A Step Toward Creating a Reactive Learning Environment", *Int. Journal of Man-Machine Studies*, 7(5), pp. 675-696, 1975
(4) W. CLANCEY : "Tutoring Rules for Guiding a Case Method Dialogue", *Int. Journal of Man-Machine Studies*, 11(1), pp. 25-49, 1979
(5) D. BOBROW : "A Question-answering System for High School Algebra Word Problems", Fall Joint Computer Conference, pp. 591-614, 1964
(6) M. ROUSSEAU : "Résolution automatique d'exercices d'électricité posés en Français", Thèse de 3ème Cycle, Université de Paris VI, 1973
(7) Y. BAR-HILLEL : "A Demonstration of the Non Feasibility of Fully Automatic High Quality Translation" in Y. BAR-HILLEL : *Language and Information*, Addison-Wesley, pp. 174-179, 1964

Peut-on parler d'une confusion entre la langue agissant comme métalangue mathématique et la langue ordinaire ? Il est bien évident que ce n'est pas parce que l'on peut tout exprimer de l'univers mathématique avec sa propre langue que cette même langue présente inéluctablement une structure mathématique. Il n'y a pas un seul *et*, un seul *ou*, mais une vingtaine, leur définition étant particulièrement incertaine. Qu'il s'agisse de la syntaxe ou de la sémantique, nous avons évoqué leurs aspects formels et fonctionnels. Si les premiers ont pour but de proposer des modèles de représentation des structures sous-jacentes aux langues analysées, les secondes s'attachent surtout à décrire le rôle des différents constituants. Les théories qui mettent l'accent sur le fonctionnel ne s'appuient pas sur la même rigueur mathématique que les descriptions formelles. Il n'est d'ailleurs pas prouvé que les langues soient clairement formalisables et il est fort pro-bable que l'homme ne les utilise pas ainsi. Dès lors, les formalismes conviennent-ils au traitement automatique des langues ?
Les activités cérébrales liées au langage semblent informelles. L'exemple que fournit la traduction illustre le fait que nous raisonnions probablement sur des significations sans passer par un formalisme quelconque. Selon ARSAC, un ensemble de règles morphologiques (formelles) permet de reconnaître les constituants d'une phrase latine. Il est alors possible de construire une phrase en français ayant la même structure syntaxique, en remplaçant les mots latins par leur équivalent français. L'opération est ici de type essentiellement syntaxique. Le sens est par contre au centre des activités de traduction simultanée où l'on exprime aussitôt dans la langue cible l'image qu'exprime la langue source. Le traitement sémantique court-circuite alors le traitement syntaxique.
On distingue dans tous les cas *la forme* d'une donnée (support matériel) et *son sens* (ce que manipule le cerveau de celui qui interprète la forme). Si l'on traite une phrase d'une langue source vers une langue cible en utilisant le formalisme, il faudra passer par une représentation des connaissances (abstraction) et la construction de nouvelles connaissances (inférences "syntaxiques") avant de parvenir à la phrase cible (interprétation). L'autre méthode consisterait à passer directement par le sens (inférences "sémantiques").

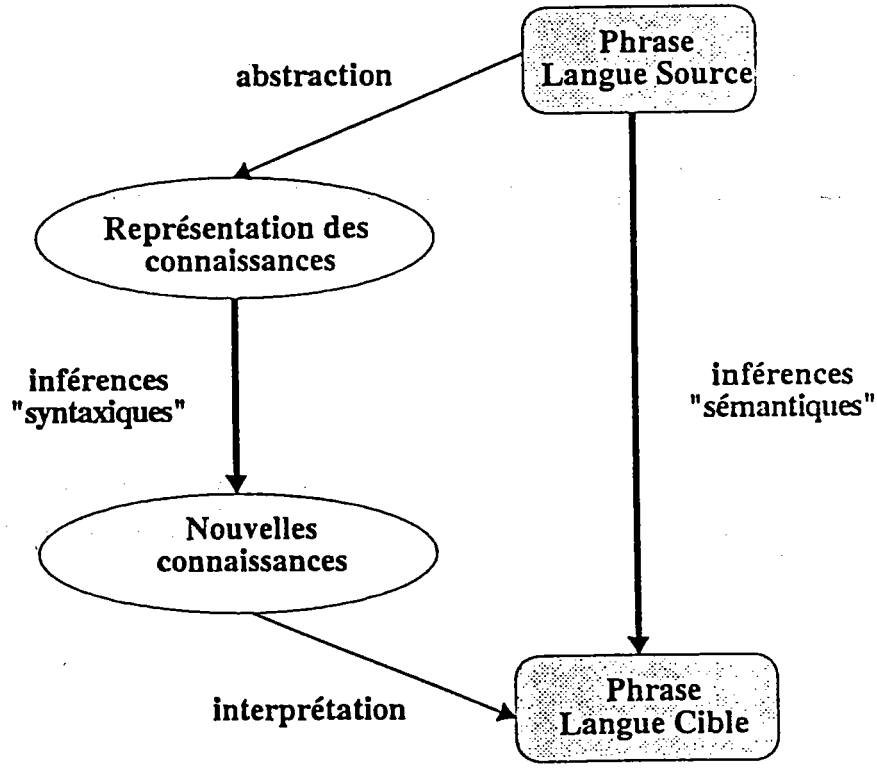

L'ordinateur doit traiter les problèmes que l'homme résout de façon sémantique. Il peut obtenir les mêmes résultats sans reproduire les différents processus ou chercher au contraire à reproduire, à un certain niveau, les opérations mentales impliquées. On se heurte alors à un obstacle de taille car, pour formaliser le sens, il faut passer par un traitement syntaxique qui ne conserve que la forme, tandis que disparaît le sens. Ceci nous conduit à une question fondamentale : *notre cerveau accomplit-il quelque chose qui ne peut pas être formalisé ?*

- Si l'on répond de façon positive, on rejoint les critiques qui affirment qu'en ce qui concerne l'homme, "tout ce qui touche à la compréhension est intimement lié à son expérience sensorielle et émotionnelle, éléments fondamentalement non formalisables". On pourra se référer à H. DREYFUS[1] qui condamne l'Intelligence Artificielle. T. WINOGRAD[2] s'en rapproche quelque peu lorsqu'il ne croit plus que la sémantique soit formalisable. Considérant que "la notion d'engagement est à la base du langage", il affirme que les machines ne seront jamais intelligentes. J. WEIZENBAUM[3], un pionnier dans le domaine, insiste sur les différences fondamentales entre l'homme et la machine et rappelle que certaines opérations seront toujours réservées à l'homme.

- Les optimistes, quant à eux, pensent que l'on peut appréhender le sens et le formaliser sans le vider de sa substance. Ils feront état d'avancées spectaculaires dues essentiellement aux apports de l'Intelligence Artificielle dont se réclament les systèmes récents et les projets de 5ème génération.

- Nous pensons qu'il est impossible d'émettre un jugement définitif. Les recherches actuelles s'attachent à étudier les limites théoriques des formalismes utilisés (développement des sciences cognitives) tout en appliquant les modèles au traitement des données (réalisation de programmes visant à renforcer la crédibilité de l'Intelligence Artificielle). Cette double perspective sera peut-être féconde, à long terme.

Nous avons par conséquent adopté une position intermédiaire. Sans condamner la T.A. et la T.A.O., nous croyons qu'elle se développera, mais en adaptant ses objectifs aux réalités linguistiques et économiques. S'il est vain de viser une traduction entièrement automatique, il n'est pas impossible de s'en approcher, en limitant les domaines abordés (systèmes en sémantique fermée (2.3.3.3.7.1), en contrôlant la forme du texte d'entrée ((2.3.3.3.9) ou en important des techniques de l'I.A.. Proposant une autre voie, nous limiterons nos ambitions à une forme particulière de traduction, à l'interprétation automatique, avec l'Automate de Compréhension Implicite (chapitre III et IV).

Nous allons maintenant illustrer les modèles de ce chapitre, avec une présentation des différentes approches, des réalisations et des projets de T.A. et de T.A.O.

---

(1) **H. DREYFUS** : *Intelligence artificielle : mythes et limites,* Flammarion, 1984
(2) **T. WINOGRAD, F. FLORES** : *Understanding computers and cognition*, Norwood, N.J. Ablex publishing corporation, 1986
(3) **J. WEIZENBAUM** : Computer power and human reason : from judgment to calculation, W.H. Freeman, San Francisco, 1976

II.

TRADUCTION AUTOMATIQUE (T.A.)
TRADUCTION ASSISTÉE PAR ORDINATEUR (T.A.O.)

2.1. Industrie de la langue[1,2]

Nées du mariage de la linguistique et de l'informatique, les machines parlent, lisent, traduisent et déchiffrent la voix humaine. Un des grands marchés du siècle.

Les industries de la langue sont en train de réaliser un vieux rêve de l'humanité : construire des machines capables de dialoguer avec l'homme. Le principal marché sera monolingue (correcteurs d'orthographe, systèmes d'accès aux bases de connaissances, systèmes d'apprentissage) mais les institutions communautaires et la mondialisation de l'économie consommeront des produits multilingues (banques terminologiques, systèmes de traduction assistée par ordinateur...).
C'est en juin 1982 (Colloque de l'Association COFORMA, Communication-Formation) qu'apparaît le concept des industries de la langue, repris dans les Actes du Colloque (décembre 1982, Palais Bourbon) sous la forme d'un titre : "Pour une filière industrielle du langage".
Cette industrie sous-tend une recherche fondamentale et une recherche appliquée qui débouchent sur des produits visant des marchés à court et moyen terme et s'appuient de plus en plus sur l'Intelligence Artificielle au point qu'elle deviendra rapidement le dénominateur commun de toutes ces activités. Leur domaine d'usage s'étend sans cesse, de la bureautique aux services, en passant par les télécommunications, les automatismes industriels, la productique, l'enseignement, la formation, la santé, l'aide aux handicapés, l'électronique grand-public, la sécurité, l'informatique, l'électronique professionnelle.
A l'intersection des activités linguistiques, des traitements informatiques correspondants, des pratiques industrielles et des marchés, parmi les nombreuses applications qui vont de la compréhension du langage naturel[3,4,5,6,7] aux systèmes experts[8,9,10,11,12], en passant par la communication parlée, les interfaces en langage naturel[13,14,15], la lecture optique[16-25], le traitement de texte[26-30], l'hypertexte[31], la documentation[32-36], nous concentrerons notre attention sur la T.A. (Traduction Automatique), la T.A.O. (Traduction Assistée par Ordinateur) et les dictionnaires électroniques multilingues.

---

(1) **R. GELLY** : "Les vrais trésors de la langue française" in *Ça m'intéresse*, novembre 1986
(2) **W. BARANES** : "Les industries de la langue" in *Qui Vive International*, septembre 1986
(3) **D. KAYSER** : "Des machines qui comprennent notre langue" in *La Recherche*, octobre 1985
(4) **J.-P. DESCLES** : "La linguistique informatique" in *Le Courrier du CNRS*, mai 1986
(5) **E. SEYDEN** : "Langage naturel : L'ordinateur comprend ce qu'il peut" in *L'Ordinateur Individuel*, octobre 1986
(6) **P. LOMBARD** : "Jouer sur le sens des mots" in *01 Informatique*, février 1987
(7) **X. DALLOZ** : "Compréhension du langage naturel à la Convention Informatique" in *Minis et Micros*, octobre 1986
(8) **C. DAVID** : "Les progrès de l'Intelligence Artificielle" in *Problèmes Economiques/Le Nouvel Economiste*, janvier 1987
(9) **J.-G. GANASCIA** : "La conception des systèmes experts" in *La Recherche*, octobre 1987
(10) **I. GROSSE** : "Quelques systèmes experts originaux" in *01 Informatique*, mai 1987
(11) **F. HAUTIN** : "Intelligence Artificielle" in *Bulletin de liaison de la Recherche en Informatique et en Automatique*, n° 111, 1987
(12) **C. BRANCIER** : "L'IA au service de la langue" in *Décision Informatique*, mai 1987
(13) **H. MADEC** : "Intelligence Artificielle : Les interfaces en langue naturelle" in *Minis et Micros*, février 1986
(14) **H. KEMPF** : "Le minitel parlera couramment français" in *Science et Vie Micro*, avril 1987
(15) **E. MONTAGNE** : "L'IA sur le réseau Télétel" in *01 Informatique*, avril 1987
(16) **A. BALAID, J.-P.HATON** : "La reconnaissance de l'écriture" in *La Recherche*, octobre 1985
(17) **D. CHARRAUT, J. DUVERNOY, L. HAY** : "L'analyseur automatique de l'écriture" in *La Recherche*, janvier 1987

2.2 La traduction

La traduction automatique et la traduction manuelle partagent tous les problèmes qui découlent de la signification. Le linguiste peut identifier et expliquer les difficultés d'un texte source. Le traducteur et l'informaticien ne disposent pas des mêmes outils et envisagent des solutions diverses qu'il est beaucoup plus difficile de déterminer en Traduction Automatique qu'en traduction humaine.
La conception et la mise au point de l'ordinateur ont suscité un enthousiasme immodéré au cours "des années 50". On pensait que des programmes adéquats traduiraient le terme d'une langue par son équivalent dans une autre langue. Cette vision simpliste assimilait le processus de traduction au déchiffrage de cryptogrammes à l'aide d'un dictionnaire. La désillusion fut profonde lorsque les non-linguistes mesurèrent la complexité et le nombre de paramètres impliqués.

2.2.1 Les outils de la traduction informatisée

La réduction brutale des subventions consacrées à ce domaine par le gouvernement des Etats-Unis, en 1955, a fait prendre conscience des difficultés du sujet.
A partir de ce moment et parallèlement à la poursuite des recherches fondamentales, les efforts se sont dirigés vers des systèmes opérationnels, chargés de soulager la tâche du traducteur. L'évolution de l'informatique a une grande influence sur la mise en place de ces outils, tandis que les gros calculateurs restent les instruments privilégiés d'applications lourdes et centralisées.
On distingue ainsi trois catégories d'outils de traduction informatisée.

1. La Traduction Assistée par Ordinateur (T.A.O.) qui offre une assistance à la traduction en augmentant la productivité du traducteur. Les limites des systèmes et la qualité

---

(18) **J.-P. PETIT** : "Acquisition de données : La reconnaissance de forme sort des brumes" in *L'Ordinateur Individuel*, décembre 1986
(19) **H. KEMPF** : "L'écriture réinventée" in *Science et Vie Micro*, juin 1987
(20) **P. DESMEDT** : "Les systèmes de reconnaissance de caractères disponibles sur micro" in *L'Ordinateur Individuel*, décembre 1986
(21) **NICHIREN** : "Scanners et lecture optique : la saisie de documents" in *Soft et Micro*, juin 1987
(22) **F. COUTROT** : "Lecture automatique de textes" in *Micro Systèmes*, août 1987
(23) **X. CHIFFELLE** : "Edition électronique : les scanners en vedette" in *01 Informatique*, n° 962, juin 1987
(24) **E. MONTAGNE** : "La lecture intelligente" in *l'Ordinateur Individuel*, mars 1987
(25) **T. OUTREBON** : "Innovatic, un précurseur" in *Décision Informatique*, juin 1987
(26) **A. CAPPUCIO** : "Turbo Lightning : L'orthographe assistée par ordinateur" in *Micro Systèmes*, octobre 1986
(27) **Y. GARRET** : "Alpha : un correcteur orthographique Borland- Larousse" in *Science et Vie Micro*, juillet 1987
(28) **Y. DARGERY** : "Au banc d'essai, les traitements de texte vedettes de la rentrée" in *Science et Vie Micro*, août 1987
(29) **M. GUENZET** : "Traitement de texte et édition" in *Décision Informatique*, mai 1987
(30) **T. COURTOIS** : "Manuscript : au-delà du texte, un traitement de document" in *Décision informatique*, juin 1987
(31) **G. BOUSQUET** : "L'hyper-texte : la grande réforme de l'écriture électronique" in *01 Informatique*, mai 1987
(32) **J. ARSAC** : "Informatique documentaire : agir sans plus attendre" in *01 Informatique*, mai 1987
(33) **F. GICQUEL** : Dossier Documentation in *01 Informatique*, mai 1987
(34) **C. FLUHR** : "Informatique documentaire : peut mieux faire" in *01 Informatique*, mai 1987
(35) **M. OLANIE** : "CD-ROM : Enfin le démarrage" in *Décision Informatique*, mai 1987
(36) **M. GUENZET** : "Intelligence Artificielle et CD-ROM" in *Décision Informatique*, mai 1987

des résultats nécessitent une révision du traducteur qui dispose d'un environnement adapté (poste de travail et outils intégrés). Certains auteurs subdivisent la T.A.O. en deux groupes[1] :

Traduction Automatique Assistée par l'Homme (HAMT Human-Assisted Machine Translation) : l'ordinateur accomplit la traduction en soi mais il y a interaction avec l'homme à différentes étapes du processus :

- Préparation du texte d'entrée (pré-édition).
- L'ordinateur demande l'aide du traducteur pour lever certaines ambiguïtés, pour expliciter des liaisons de phrase, pour choisir la traduction d'un mot ou d'une phrase parmi les possibilités qu'offrent le dictionnaire de transfert. Ces systèmes qui nécessitent une interaction homme-machine pendant le processus de traduction sont des systèmes "interactifs".
- Edition du texte de sortie (post-édition).

Traduction Humaine Assistée par Ordinateur (MAHT Machine-Assisted Human Translation) : l'homme accomplit la traduction en soi mais peut utiliser l'ordinateur dans certaines situations :

- Assistance pour la recherche dans un thésaurus.
- Accès à une banque terminologique lointaine.
- Affichage d'exemples à propos de l'utilisation d'un mot dans une phrase. Le KWIC (Key Word in Context) permet parfois de reconnaître des homographes.
- Traitement de texte avec un dictionnaire spécifique. On distingue les ADL (Automatic Dictionary Look-up) dont les entrées peuvent être introduites directement dans la traduction en utilisant une simple touche de fonction et les SDL (Selective Dictionary Look-up) qui ne livrent une traduction que pour certaines expressions.
- Mise à disposition d'informations grammaticales.
- Analyse morphologique.
- Accès à des traductions de textes voisins.
- Correction automatique des fautes de frappe.

2. La Traduction Automatique (T.A.) : Les systèmes sont prévus pour accomplir des traductions sans intervention de l'homme. On ne peut toutefois pas éviter une pré-édition et/ou une post-édition. Ces systèmes assurent le processus complet de traduction, depuis l'entrée du texte source jusqu'à la sortie du texte cible, sans intervention humaine, en enchaînant des programmes, en utilisant des dictionnaires et des règles de grammaires. Ils sont souvent limités à des domaines d'application étroitement spécifiés relatifs à un univers langagier appauvri du point de vue lexical et syntaxique.

3. Les banques de données terminologiques : L'accès est indépendant du processus de traduction. L'avantage ne réside pas dans leur automatisation (on peut trouver des mots rapidement dans un dictionnaire imprimé) mais dans le fait qu'elles soient actuelles. La terminologie évolue continuellement et les dictionnaires sont obsolètes lorsqu'ils sont édités. Un autre avantage : leur volume croît au fur et à mesure qu'interviennent les utilisateurs qui ont intérêt à les enrichir.

---

(1) J. SLOCUM : "A Survey of Machine Translation : its History, Current Status, and Future Prospects" in *J. SLOCUM (ed.) : Machine Translation Systems*, Cambridge University Press, pp. 1- 45, 1988

2.2.2 Les besoins

Le développement de ce nouveau domaine a dû se plier aux lois de l'efficacité et de la rentabilisation au fil d'une demande qui n'a cessé de croître de façon vertigineuse. Pour l'année 1988, 240 millions de pages ont été traduites en Europe, 200.000 périodiques spécialisés ont été publiés dans le monde.

La Communauté Européenne emploie en permanence 1600 traducteurs, sans compter les traducteurs indépendants à qui elle fait appel en permanence. Le prix d'une page traduite et révisée varie de 60 à 300 F., les budgets consacrés sont énormes, 21 milliards de Francs pour la CEE en 1985.

L'intérêt de la T.A.O. devient évident, lorsque les systèmes atteignent un certain niveau de qualité pour un prix raisonnable. Nous sommes ici au coeur du problème. Il n'est pas question, à notre sens, de condamner les recherches longues et coûteuses qui ont tant fait progresser la linguistique, en prétendant qu'elles conduisent ou conduiront à un échec, comme l'annonçait le rapport ALPAC[1] ou comme l'affirment aujourd'hui, pour un domaine récent, les détracteurs de l'**Intelligence Artificielle**[2]. Il serait préférable de mieux cerner le problème de la traduction automatisée, en intégrant dans le raisonnement les besoins et les moyens de tous types. La définition des buts à atteindre et des projets correspondants devrait alors respecter des critères de faisabilité et de gestion qu'elle n'observe pas souvent pour des raisons politiques ou économiques malheureuses. Il est d'autant plus regrettable de consumer une énergie considérable dans des travaux de recherche décousus ou répétés par plusieurs laboratoires que l'investissement indispensable est énorme si l'on considère les bénéfices à court terme.

2.2.3 Evolutions théoriques et techniques

Sans examiner dans le détail l'histoire de la T.A. et de la T.A.O., nous le ferons dans le paragraphe 3.3.1, prenons un peu de recul. Deux aspects majeurs se dégagent :

- En 1960, la T.A.O. et ses devancières, la Traduction Automatique ou semi-automatisé, sont au centre du traitement automatique des langues naturelles. Trente ans après, elles n'occupent plus cette place privilégiée. La communication parlée, l'informatique documentaire, la communication homme-système, les bases de connaissances, l'assistance à la compréhension et à la génération de textes concentrent sur elles l'essentiel des budgets de recherche/développement et génèrent des marchés considérables.
Beaucoup plus que le discrédit dû à des ambitions irréalistes et des résultats décevants, le vieillissement de ses fondements théoriques a privé la T.A.O. du premier rôle. La conception de l'automatisation est continuellement remise en question par le développement extraordinairement rapide des techniques de l'informatique. Les modèles linguistiques qui sont à la source des premiers systèmes ont montré leurs limites. Il ne faut cependant pas, pour autant, négliger les intérêts en jeu comme la capacité de certaines communautés scientifiques et techniques à exploiter l'information présentée dans des langues étrangères, et à communiquer directement avec ces dernières. La zone d'influence des unes s'accroît, celle des autres se réduit, tout comme les potentiels scientifique, technique, industriel et économique qui garantissent l'autonomie ou la dépendance des nations.

---

(1) ALPAC : Languages and Machines : Computers in Translation and Linguistics. Report of the Automatic Language Processing Advisory Committee, Division of Behavioral Sciences, National Academy of Sciences, National Research Council Publication 1416, Washington D.C., 1966

(2) H. DREYFUS : *Intelligence Artificielle : mythes et limites*, Paris, Flammarion, 1985

2.2.2 Les besoins

Le développement de ce nouveau domaine a dû se plier aux lois de l'efficacité et de la rentabilisation au fil d'une demande qui n'a cessé de croître de façon vertigineuse. Pour l'année 1988, 240 millions de pages ont été traduites en Europe, 200.000 périodiques spécialisés ont été publiés dans le monde.

La Communauté Européenne emploie en permanence 1600 traducteurs, sans compter les traducteurs indépendants à qui elle fait appel en permanence. Le prix d'une page traduite et révisée varie de 60 à 300 F., les budgets consacrés sont énormes, 21 milliards de Francs pour la CEE en 1985.

L'intérêt de la T.A.O. devient évident, lorsque les systèmes atteignent un certain niveau de qualité pour un prix raisonnable. Nous sommes ici au coeur du problème. Il n'est pas question, à notre sens, de condamner les recherches longues et coûteuses qui ont tant fait progresser la linguistique, en prétendant qu'elles conduisent ou conduiront à un échec, comme l'annonçait le rapport ALPAC[1] ou comme l'affirment aujourd'hui, pour un domaine récent, les détracteurs de l'**Intelligence Artificielle**[2]. Il serait préférable de mieux cerner le problème de la traduction automatisée, en intégrant dans le raisonnement les besoins et les moyens de tous types. La définition des buts à atteindre et des projets correspondants devrait alors respecter des critères de faisabilité et de gestion qu'elle n'observe pas souvent pour des raisons politiques ou économiques malheureuses. Il est d'autant plus regrettable de consumer une énergie considérable dans des travaux de recherche décousus ou répétés par plusieurs laboratoires que l'investissement indispensable est énorme si l'on considère les bénéfices à court terme.

2.2.3 Evolutions théoriques et techniques

Sans examiner dans le détail l'histoire de la T.A. et de la T.A.O., nous le ferons dans le paragraphe 3.3.1, prenons un peu de recul. Deux aspects majeurs se dégagent :

- En 1960, la T.A.O. et ses devancières, la Traduction Automatique ou semi-automatisé, sont au centre du traitement automatique des langues naturelles. Trente ans après, elles n'occupent plus cette place privilégiée. La communication parlée, l'informatique documentaire, la communication homme-système, les bases de connaissances, l'assistance à la compréhension et à la génération de textes concentrent sur elles l'essentiel des budgets de recherche/développement et génèrent des marchés considérables.
Beaucoup plus que le discrédit dû à des ambitions irréalistes et des résultats décevants, le vieillissement de ses fondements théoriques a privé la T.A.O. du premier rôle. La conception de l'automatisation est continuellement remise en question par le développement extraordinairement rapide des techniques de l'informatique. Les modèles linguistiques qui sont à la source des premiers systèmes ont montré leurs limites. Il ne faut cependant pas, pour autant, négliger les intérêts en jeu comme la capacité de certaines communautés scientifiques et techniques à exploiter l'information présentée dans des langues étrangères, et à communiquer directement avec ces dernières. La zone d'influence des unes s'accroît, celle des autres se réduit, tout comme les potentiels scientifique, technique, industriel et économique qui garantissent l'autonomie ou la dépendance des nations.

---

(1) ALPAC : Languages and Machines : Computers in Translation and Linguistics. Report of the Automatic Language Processing Advisory Committee, Division of Behavioral Sciences, National Academy of Sciences, National Research Council Publication 1416, Washington D.C., 1966

(2) H. DREYFUS : *Intelligence Artificielle : mythes et limites*, Paris, Flammarion, 1985

Les évolutions théoriques et techniques de ce secteur ont été ignorées ou diversement perçues. Une lecture attentive de la littérature consacrée aux différents systèmes révèle de nombreuses incertitudes, lorsqu'il ne s'agit pas de mensonges ou de contradictions. Les distributeurs ou responsables de marketing s'acharnent à confondre une traduction automatique avec une traduction partiellement automatique, rejettent l'idée d'une classification précise en fonction de fondements linguistiques et techniques, refusent les tests qui pourraient être défavorables et se retranchent derrière la notion de secret industriel pour entretenir un flou savant autour de dispositifs récents visant à l'amélioration de l'outil présenté. Ces préoccupations à très court terme sont condamnables.

Il est impossible de croire que des systèmes, spécialisés et construits il y a 15 ans, puissent, sans budget et sans personnel suffisant, rivaliser avec les systèmes entre-tenus à grands frais par la CEE ou les industriels japonais. Prisonniers des techniques et des modèles à partir desquels ils ont été conçus, leur modernisation est problématique, et de toute manière, ne peut être que limitée.

Il est en effet possible d'étudier et d'évaluer le coût, la vitesse et la qualité d'une traduction selon des critères à peu près objectifs. On connaît les caractéristiques que devront posséder les futurs systèmes et les investissements qu'il faudra consentir, tant publics qu'industriels, pour ne pas avoir à utiliser, dans un avenir proche, des systèmes conçus ailleurs qu'en France et pour d'autres langues sources.

L'incohérence des choix opérés par les entreprises illustre les incertitudes qui pèsent sur un secteur plein de contradictions :
- IBM France a renoncé au système ALPS, retenu cependant par IBM Canada, alors qu'IBM Danemark lui préfère LOGOS[1].
- L'Aérospatiale utilise SYSTRAN à Suresnes, recourt parfois à ARIANE et a choisi WEIDNER à Marignane.

Les deux principales estimations concernant le marché mondial de la traduction ont été réalisées par DATAQUEST en 1986 (500 millions à 4,5 milliards de dollars) et COOPERS ET LYBRAND[2] en septembre 1987 (1 à 3 milliards de dollars). Une étude récente en France situe le marché réel à 1,1 milliard de Francs et le marché potentiel à 1,6 milliards de Francs.

En résumé, nous dirons que le secteur de la T.A. et de la T.A.O. est en pleine évolution. Il suscite de grands appétits commerciaux. Les investissements consentis pour la recherche, le rachat d'anciens systèmes, leur modernisation et leur extension à d'autres couples de langue devront être rentabilisés. Le marché, face à la diversité des offres en T.A.O. et au caractère fantaisiste des caractéristiques techniques annoncées, attend des produits et des services capables de favoriser et d'accroître la circulation des informations nécessaires au progrès scientifique et technique.

Tout en améliorant le rendement des traducteurs, ces outils devront en même temps permettre de diminuer les coûts. Quels seront ces outils, qui les construira et les exportera ? Quelles langues parleront-ils ? En 1980 et pour les 9000 revues scientifiques principales, 12 % des articles étaient rédigés en français, en 1989, ils ne représentent

---

(1) A. ABOU : "Place et perspectives de la T.A.O. dans les industries de la langue" in *Actes du séminaire Traduction Assistée par Ordinateur*, Paris, pp. 7-8, mars 1988

(2) COOPERS et LYBRAND Consulting Group : Market and Industry Study for Computer Assisted Translation Systems, Canada, 1987

plus que 7 %. La tentation du "tout anglais" est une réalité, et les Etats-Unis nous promettent la machine à écrire à dictée vocale pour 1991. Le prototype mis au point par IBM à Yorktown reconnaît déjà 5000 mots, la Kurzweil Voice Writer (KVW) de KURZWEIL reconnaît 20.000 mots et a été commercialisée fin 1990 pour 140000 F. La déclaration du Secrétaire Général du Conseil de l'Europe, Marcello OREJA, a valeur d'avertissement : *"Les langues qui ne s'industrialiseront pas cesseront, à plus ou moins brève échéance, d'être des langues véhiculaires, des langues de civilisation".*

2.2.4 Architecture générale

Les modèles de la langue et les outils que nous avons présentés dans le chapitre I de notre exposé concernent la linguistique informatique et ses applications, comme la traduction automatique.
On retrouve ici l'architecture propre à tout traitement du langage naturel, avec des extensions spécifiques (des grammaires de transfert aux différents niveaux de traitement) et des missions particulières (résolution des problèmes de compréhension et de paraphrase des textes sources, transfert d'une représentation vers une autre, à partir d'une représentation contextuelle de la sémantique des catégories de la langue source et à l'aide de procédés capables de les exprimer dans la langue cible).
L'élaboration de dictionnaires de grande taille (tels que le dictionnaire informatique du LADL, Laboratoire d'Automatique Documentaire et Linguistique, paragraphe (1.4.3.6.3.1)), la description des valeurs sémantiques des catégories grammaticales et l'écriture des grammaires de transfert conditionnent la construction de ces représentations pour laquelle on dispose de trois méthodes.

1. On utilise des représentations formelles. Leur formalisme a été mis au point à partir d'une théorie linguistique. Cela revient à définir des représentations informatiques associées aux représentations formelles et aux données linguistiques.
ex. : L'adaptation des grammaires formelles de N. CHOMSKY aux exigences de l'informatique.

2. En se contentant d'une théorie peu évoluée, on construit des représentations informatiques en adaptant directement des implantations informatiques. Cela revient à fournir une interprétation linguistique aux représentations informatiques et à en justifier la pertinence théorique (R. SCHANK).

3. On utilise un formalisme emprunté à la logique (logique des prédicats...) et on l'adapte à la structure informatique pour représenter les énoncés du langage naturel (langage de programmation PROLOG).

Plus de 20 ans séparent la première version de SYSTRAN (Peter TOMA) et les systèmes conçus actuellement par les industriels japonais.

- Le traitement linguistique des langues naturelles a beaucoup évolué, de l'analyse contrastive et comparative à l'analyse sociolinguistique et pragmatique, en passant par l'analyse transformationnelle.
- La technologie informatique a effectué des progrès considérables et la conception des systèmes en a bénéficié. Les architectures matérielles et les puissance de calcul qu'elles assurent ont modifié la présentation des systèmes qui deviennent interactifs.

2.2.5 Techniques linguistiques

On a jusqu'ici classé les systèmes de T.A. en deux catégories selon qu'ils traitent ou non la sémantique. Cette distinction est trop simpliste, lorsqu'elle n'est pas fausse.

Tous les systèmes prétendent faire de la sémantique, ce qui n'est pas exact, dans le détail, et ce qui implique d'autres critères de classement.
Si l'on cherche à classer les systèmes d'après les techniques linguistiques utilisées, on pourra opposer la traduction directe à la traduction indirecte, l'approche "interlingue" à l'approche dite de "transfert" et la vision locale à la vision globale.

Traduction directe : le système est créé, à l'origine, pour traduire d'une langue dans une autre langue. Il se limite au travail minimal qui permet d'effectuer la traduction. La levée des ambiguïtés n'est réalisée que lorsque cela s'avère indispensable, et pour une langue cible donnée, sans tenir compte de ce qui serait nécessaire pour une autre langue.

ex. : G.A.T. (Georgetown Automatic Translation, paragraphe 2.3.2.1)

Traduction indirecte : l'analyse de la langue source et la synthèse de la langue cible sont deux processus totalement indépendants. Les ambiguïtés sont levées jusqu'à ce que l'on détermine le sens de l'entrée en langue source (quelle que soit la façon dont on le représente) sans tenir compte de la ou des langues cibles.

ex. : EUROTRA (European Translation System, paragraphe 2.3.5.7)

Approche "interlingue" : la représentation du sens de ce qui est entré en langue source est indépendante de toute langue. Cette représentation est utilisée dans la synthèse de la langue cible, en sortie. La notion des "universaux" est sous-jacente. La représentation d'une unité de sens serait unique, quelle que soit la langue ou la structure grammaticale.

ex. : CETA (Centre d'Etudes pour la Traduction Automatique, paragraphe 2.3.2.2)

Approche dite de "transfert" : la représentation du sens diffère, pour une unité, selon la langue dont on l'extrait ou selon la langue dans laquelle on la génère, ce qui implique une troisième phase dans la traduction. Cette phase organise la représentation spécifique à une langue selon le système d'une autre langue. Il s'agit du transfert. Le processus complet de traduction se décompose alors en trois phases : Analyse, Transfert et Synthèse. La dichotomie "interlingue"/"transfert" ne s'applique pas à tous les systèmes, les systèmes "directs" n'utilisant, précisément, aucune de ces deux approches, puisqu'ils ne cherchent pas à représenter le sens.
L'analyse décrit le texte source (lexique et structure) en définissant les relations qui lient les mots. Pour chaque mot un dictionnaire électronique fournit les données morphologiques. Un dictionnaire ou un ensemble de règles proposent ensuite les structures possibles de la phrase analysée. L'analyse reclasse les unités en groupe nominaux, groupes verbaux, groupes prépositionnels.
Le transfert : Après qu'un analyseur[1] ait décomposé la phrase en éléments structurels, on recherche l'unité lexicale qui traduira le mot du texte source, conformément aux données fournies par l'analyse, pour obtenir finalement une chaîne de mots ne respectant pas encore la syntaxe de la langue cible.
La synthèse constitue la dernière étape au cours de laquelle les unités sont assemblées dans le respect de la morphologie et de la syntaxe, à l'aide des dictionnaires et des grammaires de la langue cible.

ex. : TAUM (Traduction Automatique de l'Université de Montréal, paragraphe 2.3.2.4)

---

(1) On rencontre souvent dans la littérature le terme équivalent en langue anglaise : parser

Vision locale : les mots constituent l'unité essentielle dans la conduite de l'analyse. Des procédures distinctes déterminent le niveau de langue, traitent l'expression idiomatique, évaluent le sens, pour chaque mot, en se fondant sur le contexte (à gauche et/ou à droite). Ceci constitue un handicap très sérieux dans le cas des homographes (orthographe identique mais niveaux de langue, schémas dérivationnels et sens différents), puisqu'il n'y a pas de tentative d'analyse globale de la phrase.

ex. : SYSTRAN (System Translation, paragraphe 2.3.3.2.9)

Vision globale : le sens du mot est déterminé par son contexte, dans le cadre d'une analyse globale de la phrase (ou, rarement, du paragraphe). Le traitement des homographes pose ici moins de problèmes, dans le sens où le contexte pris en compte est nettement plus large qu'en vision locale.

ex. : METAL (Mechanical Translation and Analysis of Languages, paragraphe 2.3.2.3)

2.2.6 L'Intelligence Artificielle

Les systèmes abordés jusqu'ici sont des applications de la linguistique centrées sur l'analyse syntaxique. Les marques sémantiques sont liées aux structures syntaxiques, les études sémantiques suivent l'identification de ces structures.
L'analyse et la synthèse n'ont pas d'autre champ d'observation que la phrase. Les dimensions du contexte leur échappent. Il devient alors impossible de traiter les phénomènes comme la pronominalisation et la topicalisation.

Les projets qui s'inspirent des concepts et des méthodes de l'Intelligence Artificielle accordent à la sémantique le rôle central. Les composantes principales sont désormais l'analyse des éléments sémantiques qui remplace l'analyse des catégories grammaticales, la détermination des réseaux sémantiques (Dépendances conceptuelles de SCHANK) et la résolution des ambiguïtés et des incertitudes sur la base d'informations extralinguistiques. Le but est de comprendre le texte avant de le traduire. Nous avons eu l'occasion de présenter des résultats obtenus dans le cadre des recherches en Intelligence Artificielle (Paragraphe 1.5). Les programmes cités sont parfois très intéressants pour la Traduction Automatique mais n'apportent pas toujours une solution à des problèmes qui restent spécifiques. Il nous semble pourtant évident que ce domaine aurait beaucoup à gagner dans une combinaison des méthodes d'Intelligence Artificielle et des techniques d'analyse automatique.

2.3 Les systèmes de T.A. et de T.A.O.

2.3.1 Historique

La Traduction Automatique a près de 40 ans. Au fil d'une histoire longue et colorée, elle n'a jamais totalement convaincu. Les adeptes inconditionnels caressent les espoirs les plus fous, les ennemis irréductibles la condamnent.

De 1946 à 1964 :

Après l'avènement des premiers ordinateurs (1946) W. WEAVER et A.D. BOOTH envisagent la possibilité d'obtenir une traduction intelligible en remplaçant chaque mot d'une phrase par son équivalent. C'est à l'université de Washington (Seattle) que E. REIFLER envisage une première traduction automatique (1949) à l'aide de la machine de KING, traduction mot à mot effectuée par un automate transducteur d'états finis, incapable, par conséquent, de lever les ambiguïtés.

Commence alors une période d'euphorie, confirmée par l'apparition de revues spécialisées, la succession de congrès internationaux de plus en plus fréquentés (Conférence du M.I.T. sur la Traduction Automatique en 1952, Conférence sur la T.A. à Moscou en 1958 avec 350 participants, Conférence sur le traitement de l'information à Paris en 1959) et l'apparition des premiers systèmes :

- système japonais YAMATO (1959)

- système de KULAGINA et MEL'CUK, en URSS (1956-1957), du français vers le russe. Le partage du processus de traduction en analyse du texte d'entrée et synthèse du texte de sortie préfigure les méthodes de deuxième génération. Beaucoup plus évolué que les réalisations de REIFLER, il fonctionne sur un ordinateur et effectue une traduction en 5 étapes à partir de 3 dictionnaires, français, russe et expressions idiomatiques.

- Le système GAT (Georgetown Automatic Translation)

D'autres travaux ont lieu pendant cette période, en Grande-Bretagne, en URSS, aux Etats-Unis et au Japon. Le structuralisme américain asémantique permet alors de concevoir la possibilité d'une traduction par substitution de morphèmes.

Le tournant :

Le lancement par l'Union Soviétique du premier Spoutnik en octobre 1957 déclencha une vive réaction des américains qui mobilisèrent leurs efforts afin d'être les premiers à envoyer un homme sur la lune. La nécessité d'analyser les résultats et l'orientation de la technologie soviétique a entraîné une intense demande de traduction du russe vers l'anglais.

Thème de recherche prioritaire, la Traduction Automatique engloutit des sommes considérables et occupe plus de 40 organismes dans les années 1960. C'est à cette même époque qu'est créé à Grenoble, le CETA (Centre d'Etudes pour la T.A.).

Les espoirs entretenus en dépit de l'insuffisance des théories linguistiques et de la méconnaissance des capacités de l'ordinateur ont vite été déçus. En l'absence de résultats, le gouvernement américain chargea un comité d'évaluer les recherches en Traduction Automatique. Publié en 1964, le rapport ALPAC n'accorda aucun avenir technique ni économique au domaine. Les subventions supprimées, presque toutes les recherches cessèrent aux Etats-Unis.

1965-1970 :

Cette période fut difficile pour les autres pays. Certains chercheurs préparaient la seconde génération, que le rapport ALPAC ne concernait pas. Après "Les structures syntaxiques" de N. CHOMSKY (1958), la théorie des grammaires de cas proposée par C. FILLMORE (1958) constitue, avec les études de D.G. HAYS sur la théorie des constituants et sur celle des dépendances pour le calcul des structures syntaxiques, un nouveau progrès du point de vue de la T.A.. Les résultats acquis à l'université de Georgetown permirent de construire un système présenté en 1970 : SYSTRAN

Le schéma de la page suivante illustre la séquence des opérations qui se divise en trois étapes : analyse, transfert et génération.

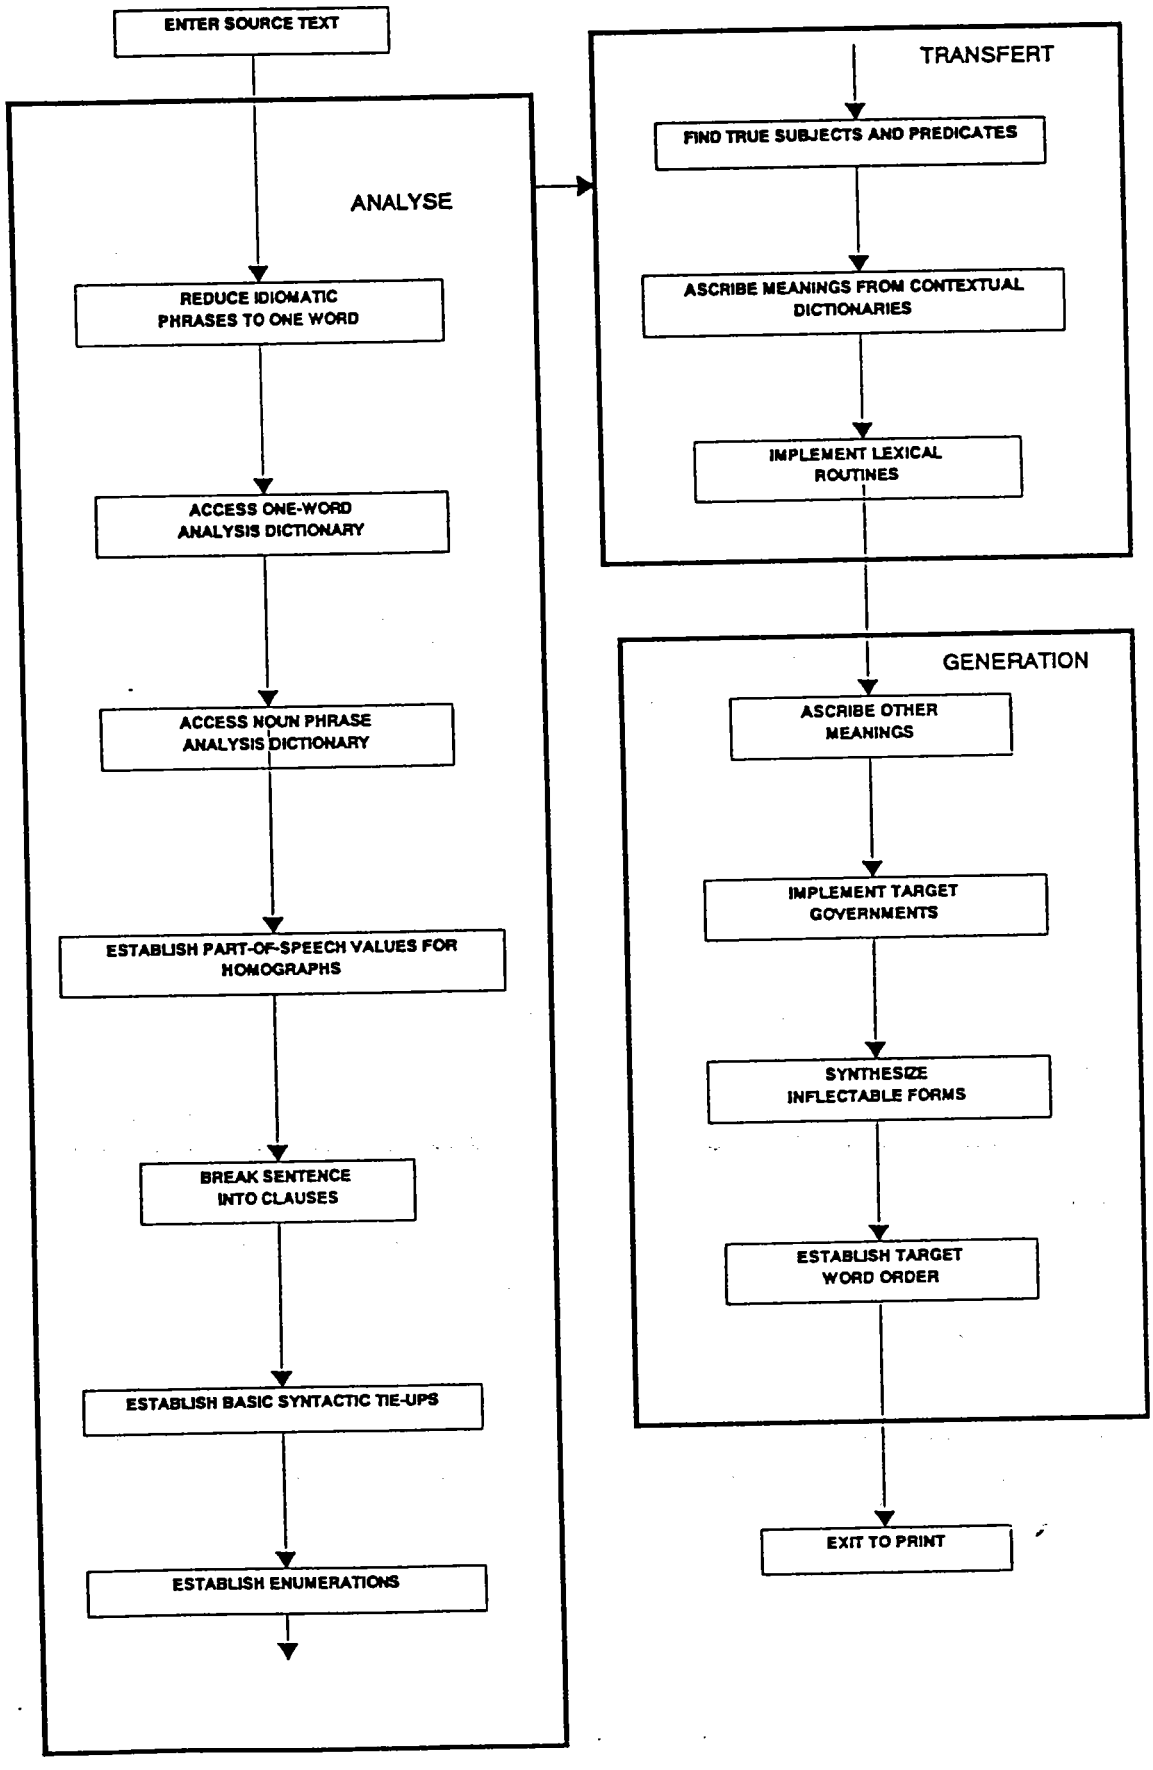
ENTER SOURCE TEXT
ANALYSE
REDUCE IDIOMATIC PHRASES TO ONE WORD
ACCESS ONE-WORD ANALYSIS DICTIONARY
ACCESS NOUN PHRASE ANALYSIS DICTIONARY
ESTABLISH PART-OF-SPEECH VALUES FOR HOMOGRAPHS
BREAK SENTENCE INTO CLAUSES
ESTABLISH BASIC SYNTACTIC TIE-UPS
ESTABLISH ENUMERATIONS
TRANSFERT
FIND TRUE SUBJECTS AND PREDICATES
ASCRIBE MEANINGS FROM CONTEXTUAL DICTIONARIES
IMPLEMENT LEXICAL ROUTINES
GENERATION
ASCRIBE OTHER MEANINGS
IMPLEMENT TARGET GOVERNMENTS
SYNTHESIZE INFLECTABLE FORMS
ESTABLISH TARGET WORD ORDER
EXIT TO PRINT

1970-1980

SYSTRAN fut presque le seul système américain, le rapport ALPAC ayant détourné les efforts de recherche vers la linguistique informatique, les théories du langage et l'intelligence artificielle.

T. WINOGRAD (1.4.3.5.4) montre expérimentalement que la compréhension du langage ne procède pas seulement de la connaissance des lois internes mais du domaine où il est utilisé, ce qui nécessite des informations et des connaissances sur ce qui lui est extérieur. Son robot est dirigé par l'intermédiaire d'un ordinateur, en langue naturelle, ici, en anglais. Les robots de type winogradien ont pour caractéristique essentielle la faculté de déduction logique et le pouvoir d'inférence (théories de Y. WILKS ou de R. SCHANK 1.4.3.3.4). Ils fonctionnent dans un univers limité et possèdent un savoir emmagasiné sous forme de dictionnaires et de relations.

L'ordinateur ne peut accéder à une telle compréhension que dans des domaines étroitement limités. (J. PITRAT et ses travaux sur le jeu des échecs).

C'est la première leçon tirée après les années 60. La seconde leçon sera la nécessité de construire des systèmes où toute amélioration et toute évolution puissent être aisément mises en oeuvre, ce qui implique une séparation : les grammaires et dictionnaires d'une part, le logiciel responsable de l'analyse et de la traduction d'autre part.

L'université de Sarrebruck développe le système SUZY à partie de 1974 et l'Institut Textile de France met au point le système TITUS appliqué à un texte source rédigé dans un langage "à syntaxe contrôlée".
Deux réalisations concrétiseront ensuite les progrès effectués à partir des conclusions citées plus haut :

- pour la première, le système canadien TAUM METEO (1977)
- pour la seconde, le système ARIANE 78 (1978).

Troisième et quatrième génération

Si l'on considère les différents niveaux de traduction, on peut estimer que les systèmes actuels correspondent au niveau de l'analyse syntaxique qui consiste à traduire une phrase en ayant identifié sa structure grammaticale.

- le niveau supérieur consiste à analyser non seulement la structure grammaticale de la phrase mais aussi son contenu sémantique. On s'intéresse au sens des mots et à leurs relations dans la phrase. Fondée sur le concept de grammaire de cas proposé par C. FILLMORE, cette approche nous mène à des systèmes de traduction automatique de troisième génération, comme celui que développe l'université de KYOTO : le "Lexicon Driven Translation System" fait appel à des règles propres à chaque mot, ce qui a conduit à construire des dictionnaires en trois niveaux :

- noyau : avec mots ordinaires 20.000 à 30.000 mots
- mots spécifiques au domaine de la traduction avec leurs règles d'utilisation
- dictionnaire personnalisé où l'utilisateur accumule ce qui lui est nécessaire.

Le dernier niveau est atteint lorsqu'il s'agir de tenir compte du contexte. Aucun système possédant une faculté de raisonnement et centrant l'analyse du langage sur le contexte n'a encore vu le jour. Un tel objectif correspond cependant au projet japonais de l'ordinateur de cinquième génération, qui n'aboutira pas avant 1998 ans si tout se déroule comme prévu.

On peut se demander s'il n'existe pas, au delà de ces niveaux de profondeur, un dernier stade qui permettrait d'obtenir une description interne indépendante de la langue. Ce langage pivot, dans une optique multilingue, permettrait de réduire le nombre des procédures de transfert d'une langue à l'autre. L'éléboration d'une grammaire du langage pivot par MONTAGUE constitue une démarche intéressante mais ses représentations ne sont pas assez précises pour décrire les phénomènes du langage avec la finesse que requiert la traduction automatique.

Présent

Les pas de géant de la technologie ont sérieusement entamé le crédit du rapport ALPAC. De plus, la quantité de documents à traduire croît sans cesse. Ces deux points laissent entrevoir une extension du domaine dans trois directions, avec toutefois la certitude de ne pouvoir espérer, désormais, de traduction automatique parfaite à 100%.

- Traduction Automatique sur gros systèmes (révision humaine indispensable), utilisés sur site ou accessibles au grand public par télématique.

- Avant que les recherches en Traduction Automatique et en linguistique ne conduisent à la mise au point des systèmes de troisième ou quatrième génération, et nous pensons qu'il faudra encore attendre longtemps, les laboratoires développeront des systèmes mixtes de traduction assistée, sur mini- ou microsystèmes, loués par l'utilisateur et autorisant le développement de dictionnaires propres :*Traduction par ordinateur assistée par l'homme* (HAMT Human Aided Machine Translation) avec le système interactif ALPS et le système WEIDNER et *Traduction humaine assistée par ordinateur* (MAHT Machine Aided Human Translation) la plus répandue actuellement.

- Station de traduction, intégrant tous les outils d'aide à la traduction, d'édition, de mise en forme et de communication.

Nous avons choisi une quatrième voie qui consiste à développer non pas un outil de traduction automatique ou partiellement automatique mais un automate capable de traiter un texte technique ou scientifique très rapidement et d'en livrer une interprétation en français dans le but :

- de permettre à un lecteur qui ne connaît pas la langue du texte source, d'en apprécier le contenu

- de lui fournir à moindre coût les éléments qui permettront de juger de l'intérêt d'une véritable traduction.

Il convient de préciser qu'il n'existe pas de coupure nette entre la MAHT et notre automate qui accomplit tout de même une traduction dans le sens ou des formes de la langue source sont mises en correspondance avec des formes de la langue cible. On pourrait y voir une forme limite de la MAHT, l'ordinateur fournissant le minimum de transfert à partir duquel le lecteur compétent "se fera une idée" de ce dont il s'agit.

Avant d'aborder les techniques que nous avons retenues et qui font l'objet du chapitre III, nous présenterons les systèmes de TA et de TAO, avec les systèmes de base (2.3.2), les systèmes actuels (2.3.3), les nombreux projets (2.3.4, 2.3.5), des grands services de traduction (2.4) et pour être complet, les banques de données terminologiques (2.5).

2.3.2 Les systèmes de base

Nous citons ces systèmes anciens pour illustrer la continuité des recherches et rappeler que certains d'entre eux sont à l'origine des nombreux développements que nous aurons l'occasion de présenter plus loin.

2.3.2.1 GAT (Georgetown Automatic Translation)

Le système GAT a été développé à l'université de Georgetown à partir de 1952 et été subventionné par le gouvernement américain. En collaboration avec IBM (1954), L. DOSTERT (anglais-russe) et BROWN (français-anglais) ont livré une version opérationnelle (1964-1979) à l'Atomic Energy Commission at Oak Ridge National Laboratory (ORNL) puis à EURATOM à Ispra (Italie) où il a été utilisé jusqu'en 1976.

Ces deux versions ont été utilisées de nombreuses années pour traduire des textes de physique du russe vers l'anglais[1]. La qualité de la traduction était très mauvaise, comparée aux traductions humaines.
Afin de passer très rapidement des documents en revue pour en déterminer le contenu et l'intérêt, le GAT était néanmoins supérieur à l'alternative : traduction lente et plus coûteuse/Pas de traduction.

Dans ce système "direct" et "local" le remplacement mot à mot précède des transpositions de mots en quantité limitée pour aboutir à quelque chose qui ressemble vaguement à de l'anglais, un mot étant défini comme un simple mot ou une suite de mots formant un "idiome". Le système ne reposait pas véritablement sur une base linguistique. Développé pour traiter un texte donné, il fallait l'adapter au texte suivant et ainsi de suite. Ces contraintes ont abouti à un système monolithique d'une complexité inextricable qui n'a pas subi de grosses modifications après avoir été livré à l'ORNL et à EURATOM. La longévité n'est pas ici une preuve de sa qualité. Elle souligne bien plus le besoin énorme des bureaux de traduction.
Le projet GAT disparaîtra en 1960 avec son incorporation dans la Société LATSEC (Peter TOMA, un des créateurs du GAT) qui développera alors le système SYSTRAN (basé sur la même technologie).

2.3.2.2 CETA (Centre d'Etudes pour la Traduction Automatique)

En 1961 l'université de Grenoble lance le projet de traduction du russe vers le français. A la différence du GAT, les chercheurs de Grenoble construisent leur programme autour d'une théorie linguistique précise, avec l'intention de conduire une analyse en structures de dépendances pour chaque phrase (approche globale) plutôt que de s'appuyer sur une heuristique intérieure à la phrase et aboutir à un contrôle limité du transfert (approche locale).

L'approche est inter-langue au niveau grammatical (utilisation d'un langage indépendant pour représenter le sens de façon neutre). La technique de transfert s'applique au niveau lexical (dictionnaire) et implique une structure qui permet de passer d'une représentation du sens à une autre.
Les techniques informatiques ne sont pas très évoluées à l'époque. Le centre adopte le langage Assembleur d'IBM[2].

---

(1) S.R. JORDAN, A.F.R. BROWN, F.C. HUTTON : "Computerized Russian Translation at ORNL" in *Proceedings of the ASIS Annual Meeting*, San Francisco, 1976, p. 163
(2) W. J. HUTCHINS : "Progress in Documentation : Machine Translation and Machine-Aided Translation" in *Journal of Documentation* n°34, june 1978, pp. 119-159

Le développement du système dura 10 ans, de 1961 à 1971. Il fut utilisé de 1967 à 1971 pour traduire 400 000 mots de textes sur les mathématiques et la physique, du russe vers le français. La découverte majeure concerne l'utilisation d'un langage pivot. Le concept sera abandonné plus tard (système ARIANE 78) lorsqu'un changement d'environnement (matériel informatique) aura stoppé le développement du CETA, immédiatement remplacé par un nouveau projet, le GETA (Groupe d'Etudes pour la Traduction Automatique).

2.3.2.3 METAL (MEchanical Translation and Analysis of Languages)[1]

Les recherches en Traduction Automatique ont débuté en 1956 à l'université du Texas (Austin). Le LRC (Linguistics Research Center), créé en 1961, a lancé le projet METAL sur le couple de langues allemand-anglais. Il s'appuie sur la grammaire transformationnelle de CHOMSKY tout en admettant ses insuffisances pour aboutir à un système opérationnel. La traduction "indirecte" est effectuée en 14 étapes. Le temps de calcul est très important (entrées/sorties dans des fichiers de données trop importants). Les premiers résultats sont obtenus en 1974 à l'aide d'un programme de 80 000 lignes de FORTRAN fonctionnant sur une machine dédiée (CDC 6600).
Interrompues pendant quelques années, les recherches reprennent grâce à de nouveaux crédits du gouvernement américain. Le programme est réécrit en LISP et fonctionne sur un interpréteur DEC-10. Des améliorations considérables amènent alors le département des langues de SIEMENS AG (Münich) à sponsoriser de nouveaux travaux à partir de 1980.

2.3.2.4 TAUM (Traduction Automatique de l'Université de Montréal)[2]

L'université de Montréal et le gouvernement canadien lancent le projet TAUM en 1965. Ayant retenu l'approche de "transfert", le système repose sur un ensemble de programmes écrits en FORTRAN et fonctionnant sur un CDC 6600 puis sur un CYBER 173. Après une période de recherche et de mise au point, des buts lui sont assignés et donnent lieu à deux projets précis :
- TAUM-METEO pour le Canadian Meteorological Center, en 1975 doit traduire automatiquement de l'anglais vers le français les bulletins de prévision météorologique. Le système sera présenté en 1976 et installé en 1977.
- TAUM-AVIATION pour traduire automatiquement de l'anglais vers le français un ensemble de manuels de maintenance en aéronautique (90 millions de mots). L'introduction d'une composante sémantique en 1977 ne comble pas les lacunes d'un système que le gouvernement canadien soumet à de nombreux tests à partir de 1979. Le coût de fabrication des dictionnaires et le coût de la traduction automatique (6 cents/mot+ 10 cents/mot de postédition) par rapport à la traduction humaine (8 cents/mot + 4 cents/mot de postédition)[3] condamne le projet en 1981.

2.3.2.5 ALP (Automated Language Processing)

Le projet de traduire automatiquement des textes mormons de l'anglais vers d'autres langues parmi lesquelles le français, l'allemand, le portugais et l'espagnol, a été lancé en 1971 à la Brigham Young University.

---

(1) W.S. BENNETT, J. SLOCUM : "The LRC Machine Translation System" in *Computational Linguistics* 11(2-3), 1985, pp. 111-121

(2) P. ISABELLE : "Machine Translation at the TAUM Group" presented at the *ISSCO Tutorial on Machine Translation*, Lugano, avril 1984

(3) A. GERVAIS : "Regular Use of Machine Translation of Russian at Oak Ridge National Laboratory", *AJCL 13*, 2, 1976, microfiche 46, pp. 53-56

Le système visait une traduction automatique. Il évolue vers un système de Traduction Assistée par Ordinateur (Interactive Translation System, ITS), à vision globale et approche de "transfert". Il ne verra jamais le jour (coût du matériel et difficultés de gérer l'interactivité avec le traducteur humain).

En 1980, pendant que les chercheurs travaillent au nouveau système ALPS (Automated Language Processing Systems) et poursuivent le développement de ITS, quelques programmeurs de la BYU rejoignent la Weidner Communications Corporation et participent à la construction du système automatique WEIDNER.

2.3.3 Présentation des systèmes actuels

2.3.3.1 Introduction

2.3.3.1.1 Contexte

Les facteurs du développement de la Traduction Automatique et de la Traduction Assistée par Ordinateur sont à l'échelle mondiale.

- Les échanges internationaux ne cessent de s'intensifier et s'appliquent aux domaines les plus variés : industrie, commerce, politique, sciences, culture, formation, recherche...
- La concurrence acharnée que se livrent les entreprises pour vendre et exporter leurs produits les obligent à disposer le plus rapidement possible d'une traduction correcte des descriptifs et modes d'emploi. C'est à ce prix qu'elles peuvent conserver un léger avantage sur le marché.
- Les technologies de l'électronique envahissent notre société et lui imposent une informatisation croissante.

2.3.3.1.2 Les utilisateurs

Les besoins que nous évoquons au paragraphe 2.2.1 se répartissent sur quatre niveaux :

- **Les états** : la demande croît au fil de l'intégration européenne. La Communauté ne pourrait pas faire face au volume des traductions généré par ses 9 langues de travail sans l'aide du traitement automatique. En 1986, le Parlement Européen a consacré la moitié de son budget aux traductions.

- **Les grands organismes** (ONU, OTAN, EURATOM, NASA, US AIR FORCE, Pan American Health Organization...), les entreprises internationales (Xerox, IBM, General Motors, Nixdorf, Triumph-Adler, Hewlett-Packard, ComputerVision, Control Data...).

- **Les petites et moyennes entreprises, les établissements d'enseignement et de recherche, les cabinets de traduction.**

- **Les particuliers** (exemple : traduction via le Minitel).

2.3.3.1.3 Les problèmes spécifiques

Bien qu'ils soient nombreux, nous ne citerons que les ambiguïtés des relations syntaxiques et sémantiques (polysémie, homographie, synonymie, interprétation de la phrase, pronominalisation, topicalisation...) pour souligner qu'une partie seulement des problèmes ont été formalisés et résolus. L'insuffisance des modèles linguistiques et la nature de l'outil informatique limiteront sans doute très longtemps les capacités des

systèmes de Traduction qui ne seront jamais en mesure de remplacer le traducteur humain pour des prestations de qualité. Ce sont des outils très précieux, cependant, pour traduire rapidement des textes techniques et scientifiques, moins complexes que les textes littéraires. Leur utilisation est de plus en plus fréquente lorsqu'il s'agit de documents dont le seul but est d'informer. La qualité de la traduction est en effet suffisante pour les lecteurs qui sont en général des spécialistes du domaine traité. Reprenons des exemples présentés par la société B'VITAL[1] (2.3.3.8.2), à Paris, en mars 1988, lors du séminaire international "Traduction Assistée par Ordinateur". Ces exemples sont tirés de textes réels et sont des traductions brutes (non révisées) obtenues par le système français-anglais traitant des documents techniques dans le domaine de l'aéronautique. Ils illustrent les possibilités de paraphrasage (grâce à la notion d'unité lexicale ou de famille dérivationnelle), les diversqes possibilités de traduction des prépositions, en fonction du contexte (critères syntaxiques et/ou sémantiques, suivant les cas) et les choix de traduction des mots en fonction du contexte (critère syntaxique et sémantique, en général).

français : *Après essai, s'assurer du fonctionnement correct de l'ensemble raccord.*
anglais : *After test, check that the coupling assembly works correctly.*
On observe le passage d'une phrase nominale "*du fonctionnement correct*" à une phrase verbale "*that ... works correctly*" et le passage d'un adjectif "*correct*" à un adverbe "*correctly*".

français : *le remplissage des pompes s'effectue dans un local fermé, très propre, à l'abri de toute possibilité d'introduction de poussière dans la graisse.*
anglais : *The pump filling is carried out in a very clean closed room (premises), away from any dust introduction possibility ((opportunity)) into grease.*
On note l'interprétation de la forme réfléchie "*s'effectue*" comme un passif et les traductions différentes de la proposition "*dans*", en fonction du contexte (traduite par "*in*" ou "*into*"), grâce à des critères sémantiques.

français : *Porter sur celle-ci la date de la dernière réception ou révision.*
anglais : *Write on this one the date of the last reception or of service.*
Le verbe "*porter*" a été traduit par "*to write*" en fonction du contexte (i.e. en fonction de la sémantique de l'objet "*date*" : critère syntaxique et sémantique).

français : *Effectuer la vidange générale et la purge de carburant (voir chapitre 12).*
anglais : *Drain in a general manner and bleed fuel (see chapter 12).*
"*effectuer la vidange*" a été traduit par le verbe seul "*to drain*" grâce à la notion d'unité lexicale.

Parmi les nombreux systèmes qui feront l'objet de ce chapitre, citons encore TITUS V (2.3.3.3.9).

Phrase d'entrée : *Les progrès récents des logiciels appropriés au traitement on-line des des systèmes d'information ont favorisé le développement des bases de données dans tous les domaines des sciences et des techniques.*

anglais : *The recent progress of the software suitable for the on-line treatment of information systems has favored the development of data bases in all the fields of sciences and techniques.*

---

(1) Cette société est issue du milieu universitaire grenoblois. Elle a été créée en 1985 avec l'appui du GETA (Groupe d'Etudes pour la Traduction Automatique) dans le but de faire passer la Traduction Assistée par Ordinateur au niveau industriel.

allemand : Die neuen Fortschritte der für die on-line verarbeitung der informations-systeme geeigneten software haben die entwicklung der databases in allen bereichen der wissenschaft und der techniken begünstigt.
espagnol : Los progressos recientes del software apropriado para el tratamiendo on-line de los sistemas de documentacion favorecieron el desarrollo de las bases de datos en todos los campos de las ciencias y de las tecnicas.

2.3.3.1.4 Les critères de choix

Les machines manquent d'intuition et rien ne permet de croire, pour l'instant, qu'elles en auront un jour suffisamment. Il convient donc de ne recourir à la Traduction Automatique ou à ses dérivés qu'en connaissance de cause. L'analyse des coûts d'utilisation sous-tend une comparaison de la traduction automatique et de la traduction manuelle en tenant compte, dans les deux cas, des coûts de révision, des méthodes et des outils utilisés[1]. Les points essentiels sont :

Coûts :
- Acquisition, installation du matériel et du logiciel.
- Entretien et maintenance
- Formation des utilisateurs
- Pour les systèmes qui ne sont pas complètement automatisés, travaux de pré-édition, post-édition, communication homme-machine en mode interactif.
- Construction et mise à jour des dictionnaires
- Amortissements

Performances :
- Evaluation des temps requis pour la saisie du texte, le traitement automatique et la révision.
- Qualité de la traduction
- Possibilités d'améliorer les performances du système en étendant le domaine d'application (Types de texte) ou en introduisant de nouveaux couples de langues.
- Convivialité

Nous passerons en revue les systèmes actuels en distinguant les systèmes commercialisés, les systèmes dédiés à des tâches spécifiques et les systèmes d'aide à la traduction.

2.3.3.2 Les systèmes commercialisés actuellement

2.3.3.2.1 ATLAS I et ATLAS II[2]

Premier système industriel de traduction (anglais-japonais) conçu par FUJITSU et disponible depuis septembre 1984, il compte à ce jour une bonne centaine d'utilisateurs. Ce système de "première génération" repose sur une approche syntaxique : la phrase est traduite mot à mot puis recomposée dans la langue cible grâce à un ensemble de règles syntaxiques. La résolution des ambiguïtés est abordée en fin de traitement au moyen d'une analyse sémantique très sommaire. Les résultats sont assez mauvais. L'intervention d'un opérateur est de plus indispensable pour la pré- et la postédition.

---

(1) G. VAN SLYPE : "Conception d'une méthodologie générale d'évaluation de la traduction automatique" in : *Multilingua*, Mouton, 1-4/1982
(2) H. UCHIDA, T. HAYASHI, K. KUSHIMA : "ATLAS : Automatic Translation System" in *Fujitsu Science & Technology Journal*, n°21, 3/1985, pp. 317-329

Le schéma suivant illustre son fonctionnement[1] :

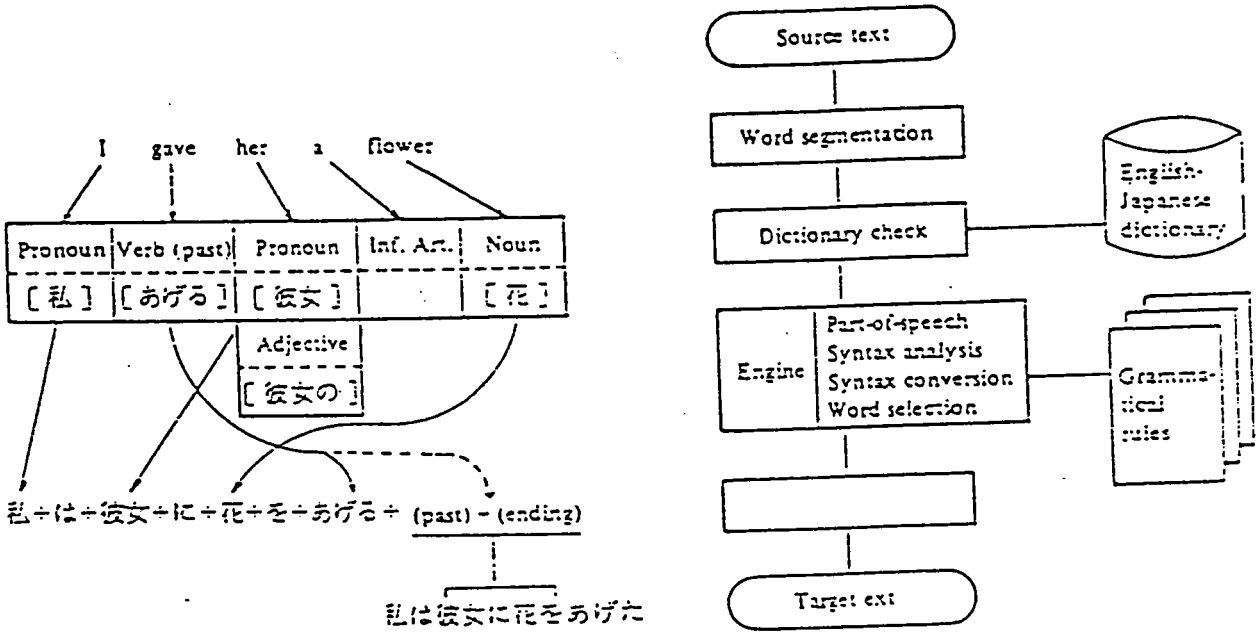

ATLAS I tourne sur un calculateur FACOM ou un S-3000 Fujitsu Minicomputer, dans un environnement OSIV (système d'exploitation). Le logiciel est rédigé en PL/1 et en Assembleur. La traduction est directe, s'appuie sur la syntaxe et les grammaires syntagmatiques (1.4.3.2.4.3) Pour la traduction anglais-japonais des textes techniques ou scientifiques, il dispose d'un dictionnaire de 53000 mots et de 25000 termes techniques. Sa vitesse atteint 60000 mots/seconde.

ATLAS II : Une "deuxième génération" de systèmes est apparue, basée sur une approche sémantique : les phrases sont analysées en fonction de leur sens grâce à "des modèles du langage" et des "modèles du monde". Représentées dans un "langage pivot" sous forme de réseaux sémantiques, structures conceptuelles indépendantes de la langue source, elles sont réécrites dans la langue cible.

Le schéma de la page suivante visualise la structure conceptuelle de la phrase :

I bought a new car.

Le réseau est constitué de noeuds et d'arcs. Les noeuds représentent le concept qui correspond au sens des mots I, BUY, CAR et NEW, les arcs des relations telles que <AGENT>, <OBJET> ou telles que <CAUSE> et <SEQUENCE>. A ces arcs binaires s'ajoutent des arcs unaires qui complètent les informations sur le temps, l'aspect et le style.

---

(1) H. UCHIDA : "Fujitsu Machine Translation System : ATLAS" in : *Proceedings of the International Symposium on Machine Tranlation*, 14 octobre 1985, Japan Information Processing Development Center, pp. 29-37

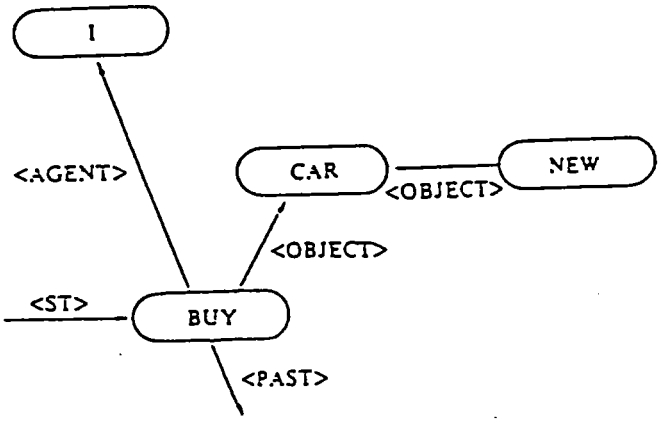

ATLAS II appartient à ces nouveaux systèmes et traduit du japonais vers l'anglais depuis fin 1985. Diffusé à une trentaine d'exemplaires, il fonctionne sur un calculateur FACOM, est écrit en langage C, utilise la technique de "langage pivot" et traduit 60000 mots à la seconde. Les résultats sont loin d'être parfaits en raison du niveau des modèles d'analyse sémantique. Comme pour ATLAS I, la traduction n'est pas totalement automatique, le processus nécessite l'intervention d'un opérateur pour des phases de pré- et post-édition.

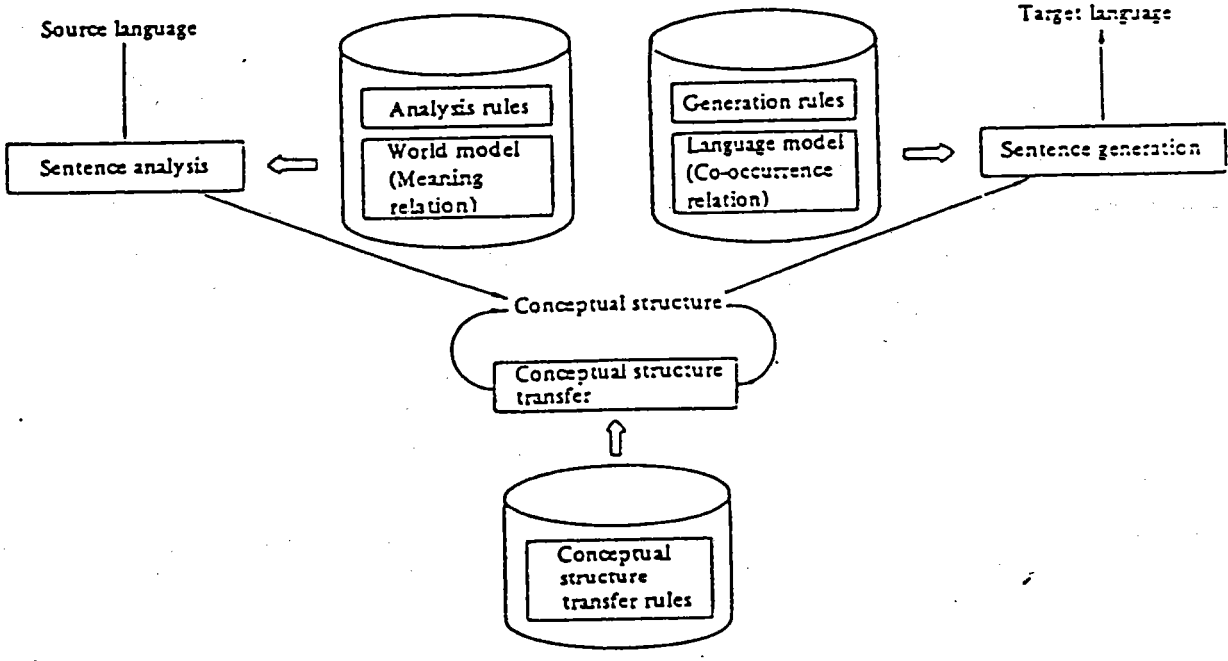

Si l'on examine le processus complet dans le détail, on distingue les trois étapes classiques : l'analyse, le transfert et la génération.

L'analyse de la phrase source doit aboutir à la représentation de son sens en une structure conceptuelle, sous la forme d'un réseau sémantique. Elle correspond à deux modules :

- SEGMENT (analyse morphologique) décompose les mots en "morphèmes" à partir de dictionnaires de mots et de relations. Les "morphèmes" sont rangés dans une liste de noeuds.
- ESPER (analyse syntaxique et analyse sémantique) parcourt la liste des noeuds en traitant chaque morphème comme un noeud terminal. Chaque noeud reçoit des informations grammaticales (ensemble d'attributs grammaticaux) et sémantiques du dictionnaire des mots.

L'analyse syntaxique et l'analyse sémantique sont parallèles et s'appuient sur des règles de grammaire indépendante du contexte. L'analyse sémantique associe des marques sémantiques au nouveau noeud et détermine la relation entre deux noeuds. On aboutit à la structure conceptuelle de la phrase source, qui est vérifiée par référence au modèle du monde.

Le transfert qui permet le passage de la langue source à la langue cible appréhende les différences non pas en ce qui concerne les mots ou la grammaire mais les concepts et la pensée. Il les traite au niveau de la représentation intermédiaire.

La génération produit le texte cible à partir de la structure conceptuelle représentée par un réseau sémantique. Cette structure subit une conversion linéaire qui la remplace par une chaîne de mots. Certaines transformations deviennent inutiles, ce qui permet non seulement au mécanisme de génération mais aux règles d'être indépendants du langage. Le système de génération réunit une "fenêtre" de génération, une liste de sortie et un interpréteur de règles. Ce dernier parcourt chaque noeud de la structure conceptuelle en déplaçant la "fenêtre" de génération qui teste les noeuds et les arcs, et retourne la liste de sortie contenant les résultats de la traduction. Les mots y sont stockés dans l'ordre de la génération qui correspond à l'ordre des mots des structures de surface. L'interpréteur de règles interprète chaque règle, parcourt chaque noeud en déplaçant la "fenêtre" de génération et sélectionne les mots en vérifiant les relations de co-occurrence et de contiguïté. Il ajoute chaque mot sélectionné à la liste de sortie.

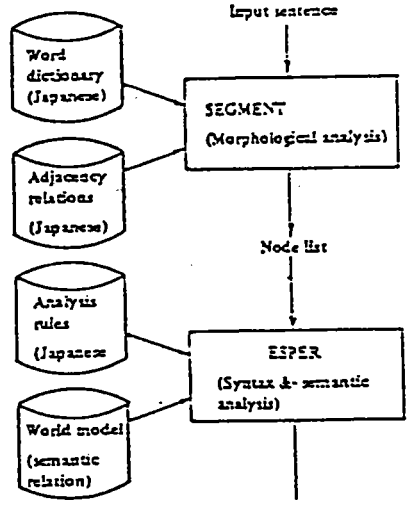

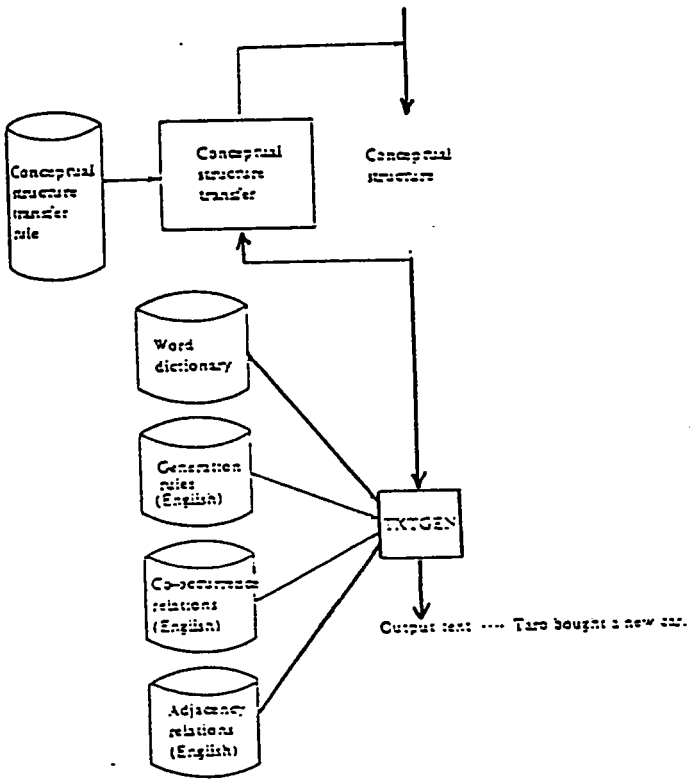

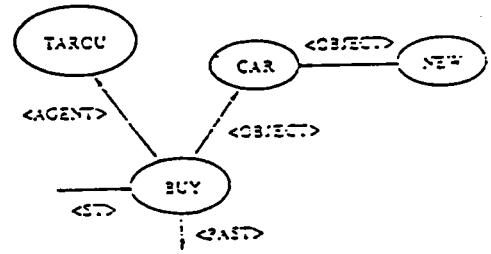

2.3.3.2.2 HICATS/JE (HItachi Computer Aided Translation System Ja-En)[1]

Lancé sur le marché en 1987 par la firme Hitachi, le système traduit du japonais vers l'anglais. Une version anglais-japonais est en préparation. Il applique une grammaire de dépendance pour l'analyse sémantique et une grammaire syntagmatique pour la synthèse. Fonctionnant sur un calculateur Hitachi M, sous VOS3, il est rédigé en PL/I et en GDL. La pré- et post-édition sont interactives. La traduction japonais-anglais s'applique à des textes techniques ou scientifiques, à des catalogues et à des brevets. Sa vitesse atteint 60000 mots/seconde. L'utilisateur peut établir son propre dictionnaire.

2.3.3.2.3 LOGOS[2,3,4]

La société LOGOS a été créée en 1969 (B. E. SCOTT) aux Etats-Unis (Waltham, Massachusetts) pour effectuer des recherches en linguistique automatique et développer des systèmes de Traduction Automatique. De 1970 à 1972 elle met au point pour l'US Air Force un système fonctionnant sur le couple anglais-vietnamien qui permettra de traduire plus de 5 millions de mots. Elle travaille ensuite sur les couples anglais-russe et anglais-parsi. A partir de 1981, l'arrivée de nouveaux investisseurs oriente les recherches vers des produits commercialisables. En 1982, SIEMENS finance les couples anglais-allemand et allemand-anglais.

---

(1) HITACHI : "Research on Machine Translation in Hitachi Ltd", *Technical note*, Systems Development Laboratory, Hitachi Ltd, Tamaku, Kawasaki, 19981
(2) C.O. STAPLES : "The LOGOS Intelligent Translation System", Presented at the *Joint Conference on Artificial Intelligence*, Karlsruhe, août 1983
(3) P. WHEELER (LOGOS Computer Systems Deutschland GmbH, Frankfurt).
(4) Documents fournis par N. DROUIN, Directeur et Vice Président exécutif de LOGOS Canada

Depuis 1984, LOGOS est implanté aux Etats-Unis (Mount Airlington, Boston), en Europe (Francfort, Zurich) et au Canada (Montréal, Ottawa).

L'ensemble de logiciels proposés par LOGOS pour les couples anglais-français, anglais-allemand, anglais-espagnol, allemand-anglais et allemand-français se compose de trois parties :

THE INTELLIGENT TRANSLATOR : Ce module de traduction reprend les trois étapes classiques de l'analyse, du transfert et de la génération.

ALEX (Automatic Lexicographer) : Option "obligatoire", ce programme permet d'introduire des données dans le dictionnaire de l'usager (mais en aucun cas dans le dictionnaire de LOGOS qui est intégré au système de base). L'usager construit lui-même son dictionnaire, spécifique à son organisation et aux domaines qu'il traite.

```
                    LOGOS ÜBERSETZUNGSSYSTEM
                    Wörterbuchfunktionen: ALEX

 Grundform des deutschen Wortes eintragen        Sachgebiets-Code
      Maschinenführung                             000  GENERAL USAGE

  Wortart            Eintragsart       Genus
    _ Substantiv       _ Wort            _ Maskulinum
    _ Adjektiv         _ Abkürzung/      _ Femininum
    _ Adverb             Akronym         _ Neutrum

Wenn  ein Kompositum ist, Grundwort angeben
      Maschinenführung

                                         Falls vorhanden, die abgeleitete
 Englischen Transfer eintragen:          Adjektivform eintragen
      machine guide
```

```
                    LOGOS ÜBERSETZUNGSSYSTEM
                    Wörterbuchfunktionen: ALEX

 Grundform des deutschen Wortes eintragen        Sachgebiets-Code
      Maschinenführung                             140 Engineering

  Wortart            Eintragsart       Genus
    ■ Substantiv       ■ Wort            _ Maskulinum
    _ Adjektiv         _ Abkürzung/      ■ Femininum
    _ Adverb             Akronym         _ Neutrum

Wenn  ein Kompositum ist, Grundwort angeben
      führung

                                         Falls vorhanden, die abgeleitete
 Englischen Transfer eintragen:          Adjektivform eintragen
      machine guide
```

SEMANTHA (Semantic Table) : Cet utilitaire vendu en option et fonctionnant en mode interactif permet à l'utilisateur de rentrer dans le programme de nouvelles règles sémantiques. Il stocke un ensemble de règles conceptuelles destinées essentiellement à repérer les constituants des formes verbales pour restituer les nuances au niveau du language de tranfert (langue cible).

Deux points caractérisent l'approche des concepteurs de LOGOS :
- Les informations concernant la langue source et la langue cible sont rangées dans des fichiers distincts, ce qui a permis d'étendre le nombre des couples de langues sans réécrire à chaque fois l'ensemble du système.
- La sémantique est intégrée dans l'algorithme de traduction au moyen d'un language de type sémantico-syntaxique, le SAL (Semantic Abstraction Language), de structure arborescente. Le programme traduit la chaîne source en SAL **avant de l'analyser**. La continuité est ainsi assurée entre la sémantique et les traitements lexical et syntaxique.

L'analyse est descendante, de gauche à droite. Elle ne s'applique pas à une chaîne en langue naturelle ni à une représentation symbolique de cette chaîne, mais à une chaîne exprimée en SAL et riche en informations de nature sémantique. Ceci permet de réduire la complexité du traitement du sens, particulièrement redoutable lorsqu'il s'agit de la langue naturelle. Il est difficile de caratériser l'approche retenue par LOGOS qui, à notre sens, tient des systèmes à transfert (sa grammaire est un ensemble de règles de transfert) et des systèmes à "language pivot" (la traduction initiale du texte source en language SAL peut être assimilée à une technique "inter-langues").
Le processus de traduction peut être décomposé en neuf étapes. Nous allons les résumer et les illustrer par quelques exemples empruntés à P. WHEELER (LOGOS Computer Systems Deutschland GmbH, Frankfurt).

Etape 1 : Le texte source est mis sous une forme telle qu'il puisse être traité automatiquement. Les marques de formatage sont conservées pour être réutilisées dans la dernière étape. Voici un exemple qui montre le texte original en allemand et sa traduction anglaise dans le même format :

```
TECHNISCHER BERICHT   Berichts-Nr.     00/000-000
                                       zu Projekt Nr. 00 111 222


Verteiler:123 456/789 321 654 100 200 1/111 2/222 X11 Y22


"Bearbeitungszeiten für B88-XXX und B88-XYYY"


1.      Alte Maschinengeneration, konventionell gesteuert.

                                                  Maschinen-Typ
        Spitzendrehmaschine                       0.000/00
        XXX          Außendrehautomat             1.111
        YYY          Innendrehautomat             2.222



2.      Neue Maschinengeneration, B88-gesteuert

                                                  Maschinen-Typ
        XXX          Außendrehautomat             3.333
        YYY          Innendrehautomat             4.444
        XXYY         Außen/Innendrehautomat       5.555
```

Technical report Report-no.. 00 /000-000
To project no. 00,111,222

Distributor-:123 456/789 321 654 100 200 1/111 2/222 X11 Y22

"Machining times for B88-XXX and B88-XXYY"

1. Old machine generation, conventionally regulated.

		Machinery-type
Prick center lathe		0.000 /00
XXX	Automatic outside lathe	1.111
YYY	Automatic inside lathe	2.222

2. New machine generation, 888-regulated

		Machinery-type
XXX	Automatic outside lathe	3.333
YYY	Automatic inside lathe	4.444
XXYY	Outer/automatic inside lathe	5.555

La première et la dernière étape sont en fait extérieures au processus de traduction. Leur adaptation à différents types de matériel est un facteur de portabilité avantageux.

Etape 2 - étape 3 : L'accès au dictionnaire s'effectue en deux temps. On parcourt d'abord le dictionnaire des mots à fréquence élevée (mots outils, modaux, expressions numérales et particules identiques à un substantif), ce qui représente les éléments de base d'une langue (1 000 éléments environ) et justifie la protection du fichier en écriture. L'utilisateur ne peut pas en modifier le contenu. Le deuxième dictionnaire contient les mots courants de la langue (85 000 pour le système allemand-anglais, 27 000 pour le système anglais-allemand).

On consulte les tables morphologiques (180 tables) pour tester les chaînes de caractères dont la terminaison est recensée. On compare la chaîne privée de la terminaison à une liste de racines. Si l'on repère une racine, on vérifie qu'elle est bien compatible avec la terminaison rencontrée avant de considérer la chaîne comme un mot ou un groupe d'homographes.

Etape 4 : L'analyse détermine les classes lexicales en traitant séquentiellement les différentes possibilités morphologiques, puis en étudiant le contexte syntaxique (selon le principe des paires de mots autorisées ou non). Les combinaisons rares sont retenues jusqu'à ce qu'elles soient rejetées par les tests du contexte syntaxique. Les expressions figées sont également localisées lors de cette étape ("im Laufe der Zeit....").

Etape 5 : C'est le début du processus de traduction, avec la recherche des groupes nominaux. A partir de cette étape, le système consulte des tables de règles (10 000 schémas de combinaisons syntaxiques). Les noyaux sont identifiés et les extensions (adjectifs) stockées.

Prenons la phrase :

Alle funktionsfähigen Großrechner und brauchbaren Bildschirme, die zur Verfügung stehen, werden heute nach Frankfurt geschickt.

A la fin de l'étape, la phrase pend la forme suivante :

Großrechner und Bildschirme, die zur Verfügung stehen, werden nach Frankfurt geschickt.

Les adjectifs *alle, funktionsfähigen* et *brauchbaren* ont disparu. La méthode consiste à condenser le texte au maximum pour réduire la complexité du traitement. Les trois unités *alle, funktionsfähigen* et *Großrechner* ne sont plus considérées comme un groupe nominal de trois éléments mais comme un substantif. Le code qui correspond à *Großrechner* a été complété pour décrire les deux adjectifs qui ont disparu de l'écran.
Le second résultat de cette étape est le remplacement des deux groupes nominaux par leur représentation dans la langue source. S'il était possible de visualiser la phrase à ce stade de l'analyse, elle aurait la forme suivante :

Mainframes und screens, die zur Verfügung stehen, werden heute nach Frankfurt geschickt.

Les concepts *all, operational* et *usable* qui se rapportent à *mainframes* et à *screens* sont encore sous forme de code. La consultation des tables sémantiques intervient avant le démarrage de la sixième étape. Si les tables donnent une nouvelle correspondance au terme *Großrechner* lorsqu'il est modifié par *alle* ou *funktionsfähig*, le code est modifié en conséquence.

Etape 6 : La "condensation" des groupes nominaux complexes est poursuivie aussi loin que possible. *Alle funktionsfähigen Großrechner und brauchbaren Bildschirme* a donné *Großrechner und Bildschirme* qui est à son tour réduit à *Großrechner* avec la modification du code que cela implique.
Cette étape traite les relatives et les complétives (ou assimilées, comme les chaînes entre parenthèses) en les confrontant d'abord avec la table sémantique. Une première règle indiquera qu'en combinaison, *zur* et *Verfügung* ne doivent pas être associés aux formes courantes du dictionnaire *to the availability* mais à *available* - classe des adjectifs. Une seconde règle indiquera que le verbe *stehen* associé à *zur Verfügung* ne doit pas être traduit par *stand* mais par *be*.
Après ce traitement sémantique, les parties de phrase sont condensées, les mots qui restent sont traduits dans la langue cible et la relative disparaît.
La phrase a maintenant la forme :

Großrechner, heute nach Frankfurt werden geschickt.

Etape 7 : le système traite les combinaisons préposition-substantif. Selon la méthode décrite précédemment, *nach Frankfurt* devient *Frankfurt*. Il lui est également possible de confronter des propositions complètes aux données des tables sémantiques. Pour la phrase citée en exemple, il pourrait trouver une règle préci- sant que *schicken* + objet(contexte informatique) ne se traduit pas par *send* mais par *transport* ou *transfer* selon le choix du traducteur.

Etape 8 : Les éléments de la phrase sont assemblés. L'examen du verbe permet de distinguer ce qui est sujet de ce qui est complément, quels éléments modifient le verbe... Les blocs sont réorganisés dans l'ordre de la langue cible. (*which available are* devient *which are available*).

Etape 9 : Les codes SAL sont traduits en langue normale. Les formats stockés au cours de la première étape sont restitués et l'on obtient la sortie :

All operational mainframes and usable screens which are available are transported today to Frankfurt.

Il faut souligner que les règles sémantiques fournies avec le logiciel s'appliquent aux termes de base. Si l'usager souhaite créer des associations spécifiques au domaine ou au texte qu'il traduit, il les introduira comme étant une nouvelle règle sémantique. Ces règles faisant intervenir obligatoirement des unités lexicales, il serait plus exact de parler de règles contextuelles.

Exemples[1] de traductions obtenues avec le système LOGOS :

Texte source

Allgemeine Nebenzeiten sind bezahlte Betriebspausen, Anlauf- und Auslaufzeiten.
Die Anlaufzeit ist der Zeitraum von der Inbetriebnahme des ersten Aggregates eines Betriebsmittels bis zum Ausstoß des ersten brauchbaren Produktes. Die Auslaufzeit ist der Zeitraum vom Ende der vollen Beaufschlagung des ersten Aggregates eines Betriebsmittels bis zur Außerbetriebnahme des letzten Aggregates eines Betriebsmittels.
Rüstzeit ist der zum Umstellen der Betriebsmittel auf entsprechende Formate, auf die Füllgutart und -mengen usw. benötigte Zeitraum. Dies geschieht überwiegend z. B. bei Formatwechsel durch Maschineneinstellung (Rüstzeit I) oder bei Präparate- bzw. Auftragswechsel (Rüstzeit II). Zur Rüstzeit gehört auch die Schmierung der Maschinenführungen.

Traduction brute

General non-operating times are paid breaks, start and shutdown times.
The start time is the period of/by the start-up of the first aggregate of a resource up to ejection of the first needable product. The shutdown time is the period of/by the end of the full admission of the first aggregate of a resource up to the taking out of operation of the last aggregate of a resource.
Set-up time is the one to convert the resources to corresponding formats, on the product type and mix period required etc. This occurs predominant e. g. during/upon format change via machine setting (set-up time I) or with preparation or change in order (set-up time II). The lubrication of the machine guides belongs at set-up time also.

(1) Extrait de **P. WHEELER** : "LOGOS" in *Sprache und Datenverarbeitung*, 9. Jahrgang 1985 Heft 1, 11/21, pp. 11-21

Traduction révisée

General non-operating times are paid breaks, start and shutdown times.
The start time is the period from the start-up of the first unit of a machine up to discharge of the first usable product. The shutdown time is the period from the end of the full-scale working of the first unit of a machine up to the switching off of the last unit of a machine.
Set-up time is the period required to convert the machinery to corresponding formats, to the products types and quantities etc. This occurs predominantly e. g. at format changes via machine setting (set-up time I) or with changes in orders or preparations (set-up time II). Lubrication of the machine guides belongs to set-up time also.

Ci-dessous, un autre exemple[1] :

Automatische deutsch-englische Übersetzung mit OIS von Wang

Logos Computer Systems, Inc. hat ein Übersetzungsprogramm mit Datenbank entwickelt, das dem Benutzer eines Wang Büro-Informationssystems maschinelle Übersetzung vom Deutschen ins Englische ermöglicht. Ein Übersetzer kann mit dem LOGOS Automatic Translator bis zu 10.000 Wörter pro Tag textgetreu übersetzen.

Ein neuer Algorithmus. Die Stärke des LOGOS Systems liegt in einem neuen Algorithmus, der fortschrittliche Methoden künstlicher Intelligenz zur Lösung syntaktischer und semantischer Probleme anwendet. Frühere Versuche waren durch das Prinzip ein Wort/eine Bedeutung – oft die falsche Bedeutung – zum Scheitern verurteilt. LOGOS berücksichtigt die Bedeutung des Wortes innerhalb eines Satzes. Das Ergebnis ist ein Übersetzungssystem, das allen bisherigen weit überlegen ist.

Einzigartiger Systementwurf. LOGOS ist ein von einzelnen Sprachen unabhängiges Übersetzungssystem. Jede Sprache ist in ausbaufähigen Tabellen gespeichert. Logos und die Übersetzer können die Sprachtabellen laufend erweitern und so kontinuierlich genauere Übersetzungen erstellen, ohne erneut programmieren zu müssen. Deutsch-Englisch ist die erste Sprachengruppe, die Logos herausgibt.

German-English Automated Language Translation on the Wang OIS

With a Wang Office Information System (OIS) and a translation program available from Logos Computer Systems, Inc., it is now possible to automate the translation of German into English. The LOGOS Automatic Translator™ allows one person to translate up to 10,000 words per day with a high rate of accuracy.

A Powerful Algorithm. The power of the LOGOS software is in its new translation algorithm, which applies advanced techniques of artificial intelligence to the problems of syntax and semantics. The result is machine translation superior to any produced in the past, when systems were limited by the principle of one-word/one-meaning – often the wrong meaning. LOGOS is sensitive to context – how the meaning of a word is influenced by the words around it.

Unique System Design. The LOGOS software features a translating program that is independent of the languages involved. Language definitions reside in memory in separate expandable tables. Users can extend the language tables, increasing the accuracy of the translation without having to reprogram. German-to-English is the first set of tables released by Logos.

Extrait de C. O STAPLES : "The Logos Intelligent Translation System", presented at *the Joint Conference on Artificial Intelligence*, Karlsruhe, West Germany, August 10, 1983

Der Übersetzungsvorgang. Bisher wurden zur elektronischen Sprachübersetzung immer große Computersysteme benötigt. Mit der speziellen Übersetzungseinrichtung von Wang (TRD) und der Übersetzungssoftware von Logos können elektronische Übersetzungen jetzt auf kostensparenden und für viele Zwecke geeigneten Text- und Datenverarbeitungssystemen ausgeführt werden.

Schließen Sie die Übersetzungseinrichtung einfach an Ihr Wang Büro-Informationssystem an, weisen Sie der Logos Übersetzungssoftware, die ein Lexikon mit 100.000 Wörtern enthält, 50 MB Plattenraum zu und überlassen Sie den Rest dem System.

Eingabe. Sie rufen an Ihrem OIS Arbeitsplatz das LOGOS Übersetzungsprogramm auf, wählen die zu übersetzenden Texte aus und drücken auf AUSFÜHREN. Die Dokumente werden in die Warteschlange für LOGOS eingereiht. Während LOGOS in dem im Hintergrund ablaufenden Stapelbetrieb übersetzt, können Sie auf Ihrem OIS System andere Arbeiten ausführen.

Anwendungen. Der Logos Automatic Translator läßt sich für eine Vielzahl von Bereichen, einschließlich wissenschaftlicher, technischer und kommerzieller Dokumente, einsetzen.

Ausgabe. Innerhalb von 24 Stunden können bis zu 10.000 Wörter übersetzt werden. Der Statusbericht zeigt an, welche Übersetzungen fertiggestellt sind. Der Übersetzer kann die einzelnen Dokumente nun ganz in englischer Sprache auf den Bildschirm rufen und Korrekturen in der Sprache oder Änderungen im Stil vornehmen. Er kann sie auch in einem Format auf dem Bildschirm anzeigen, in dem auf jeden deutschen Satz seine englische Übersetzung folgt. So können die beiden leicht verglichen werden.

Vorteile. Der LOGOS Automatic Translator vermindert nicht nur die Übersetzungszeit für den Benutzer, sondern ermöglicht auch ein neues Maß an Genauigkeit und Übereinstimmung innerhalb eines Textes und von einer Übersetzung zur nächsten. Da es an das Textverarbeitungssystem von Wang angeschlossen ist, ermöglicht LOGOS Übersetzungen in großem Umfang, und die Kosten bleiben im Rahmen. Die mechanische Arbeit wird vom System erledigt, und Beurteilung und schöpferische Leistung bleiben dem Übersetzer überlassen.

Das Wang OIS System. Die Familie der Büro-Informationssysteme (OIS) bietet integrierte Informationssysteme mit der bewährtesten, fortschrittlichsten und am einfachsten anzuwendenden Textverarbeitung, die Sie kaufen können: Wang Textverarbeitung. Über 100.000 Benutzer haben Wang zu einem der größten Lieferanten von Bildschirm-Textverarbeitungssystemen der Welt gemacht. Merkmale wie einfache Bedienung, Kompatibilität und Erweiterungsfähigkeit gewähren maximale Produktivität und Rentabilität.

Die vielseitigen OIS-Systeme verbinden Wang Textverarbeitung mit anderen fortschrittlichen Eigenschaften, um allen Informationsbedürfnissen Ihrer Firma gerecht zu werden. Ergänzungen wie Mailway® (das elektronische Post- und Nachrichtensystem), WangNet (Breitband lokales Netzwerk) und WISE (Wang Inter-System Exchange), Wang's OIS Verbundsystem, ermöglichen erhöhte Leistungsfähigkeit und Produktivität im Büro.

Mit Wang ist Ihre Investition geschützt. Wang Systeme werden von einem weltweiten Netz von über 4000 Fachleuten unterstützt, die Wartung und Beratung für Wang Systeme bieten.

How The Translation Facility Works. Until now, electronic language translation has required the resources of large computer systems. Now, with the optional Wang Translation Device (TRD) and LOGOS software, electronic translation can be performed on cost-effective, multi-purpose Wang OIS systems, fully integrated with Wang's proven capabilities for text editing and data processing.

Simply attach the TRD to your OIS, allocate 50MB of disk space to the LOGOS programs, which include a 100,000 word dictionary, and let the system do the rest.

Input. At your OIS workstation, through a simple menu prompt, select "LOGOS" and press EXECUTE. Now select a document in German from your word processing system library. Press EXECUTE and it will enter the queue for translation. While LOGOS translates the document in a background batch mode, you can perform other tasks on your OIS.

Applications. This system can accommodate a wide variety of applications, including scientific, technical, and commercial documents.

Output. The Translation Facility can translate over 10,000 words in a 24-hour period. A status report will tell the user which documents have been translated.

The user can display the complete English translation on the screen to make any desired changes in style or usage, or the document can be brought to the screen in a format that compares each English sentence with its German counterpart.

Benefits. The LOGOS Automatic Translator not only decreases translation time for the user, but provides a new degree of accuracy and consistency. Its interface with Wang word processing now makes possible high volume translation on the Wang OIS while keeping costs manageable. Mechanical labor is done by the system, leaving matters of judgment and creation to the human translator.

Wang OIS. The Office Information Systems family are Integrated Information Systems that feature the most proven, and easiest-to-use word processing you can buy: Wang word processing. Over 100,000 users have made Wang the world's number one supplier of video display word processing systems. Features like ease-of-use, compatibility, and expandability ensure maximum productivity and return on your investment.

The versatile Wang OIS systems combine Wang word processing with other advanced features to meet all the information processing needs of your company. Options such as Mailway® electronic mail, WangNet broadband local area networking, and the Wang Inter-System Exchange (WISE), help to further increase office efficiency and productivity.

With Wang your investment is protected. Every system is backed by a worldwide network of over 4,000 people who service and support Wang systems.

En ce qui concerne le contexte d'utilisation, LOGOS tourne sur ordinateur IBM ou IBM compatible (système d'exploitation MVS et VM/CMS), sur WANG (système VS), sur WANG OIS140 Wordprocessor et sur UNISYS (système UNIX). Les documents techniques fournis par la firme recommandent une mémoire principale de 1 MB et des capacités de 130 MB par couple de langues. Les logiciels sont écrits en VS Fortran et en Assembleur. Il traduit les textes techniques à une vitesse de 20000 mots/24 heures.
Le système n'est pas vendu mais livré avec une licence d'utilisation. Le prix d'achat d'une configuration moyenne peut être évalué à 350 000 F auxquels il faut ajouter 70000 F de droit d'utilisation (y compris la formation, la libre utilisation pendant les trois premiers mois et l'assistance sur site). Passé ce délai, il faut compter environ 5000 F/mois pour la licence d'utilisation (3 000 lignes /mois) et 1,5 F par ligne supplémentaire (10 mots). A titre d'indication, nous précisons qu'une traduction technique effectuée de façon traditionnelle pour 175 F (320 F si elle est confiée à un bureau de traduction) revient à 60 F avec LOGOS. Ces chiffres sont approximatifs et ne tiennent pas compte du couple de langue ni du type de texte.
Plus précisément, le prix du mot traduit est de 37 centimes après 18 mois d'utilisation, en incluant tous les coûts, le logiciel, l'équipement, le personnel et l'organisation. Une étude des coûts beaucoup plus poussée révèle que le gain de productivité, même minime, est d'autant plus rentable que le volume des textes à traduire est important. En 1985, LOGOS était le système le plus vendu sur le marché européen (26 %), suivi par WEIDNER (23%), SYSTRAN (13%) et ALPS (12%)[1].

2.3.3.2.4 LINGUISTIC PRODUCTS[2]

La société Houston Texas commercialise une série de modules CAT (Computer Aided Translation) qui fonctionnent de façon interactive, pour les couples anglais-français, anglais-espagnol, anglais-suédois et anglais-danois.
Le système de traduction directe livre une traduction mot à mot de mauvaise qualité. C'est un produit bon marché qui a le mérite de fonctionner sur les microordinateurs compatibles IBM PC/XT. Les services de douane du Texas utilisent le système espagnol-anglais disponible depuis peu. De nouvelles versions sont prévues dans l'année avec 16 couples de langues, dans les deux sens.

2.3.3.2.5 METAL[3]

Le système METAL est commercialisé depuis peu sous le nom de LITRAS par la firme SIEMENS et ne fonctionne que sur le couple anglais-allemand. C'est un système indépendant de la langue (**module d'analyse**) auquel sont associées des composantes propres aux langues traitées (les **règles de grammaire** et les **dictionnaires**).
- Le même **module d'analyse** peut servir à traduire vers différentes langues. Il est alors plus simple d'ajouter de nouvelles langues cibles à un couple existant que de développer un nouveau couple à chaque fois.
- Les **règles de grammaire** servent à analyser les phrases. Les concepteurs de METAL sont partis du principe qu'il existait une infinité de structures. Certaines règles sont donc récursives, ce qui présente deux avantages : la possibilité de reconnaître des constructions peu usitées et la réduction du nombre de règles (seulement 500 pour METAL).

---

(1) Extrait de presse : COMPUTERWOCHE AKTUELL, numéro du 19. 12. 1986, "Le marché européen de la traduction automatique jusqu'en 1990", (source : Dataquest).
(2) S. MELI : "Informationsmarkt der maschinellen übersetzung" in *Terminologie et Traduction*, Commission des Communautés Européennes, 1989, p. 84
(3) Documents recueillis auprès de J. SLOCUM à l'occasion d'une visite de son laboratoire à l'université d'Austin (Texas).

- Le dictionnaire contient des informations grammaticales, morphologiques et syntaxiques, ce qui permet à METAL d'appréhender les fonctions de chaque mot dans la phrase. Son organisation est hiérarchisée. Au sommet, les mots outils (conjonctions, prépositions et déterminants), vient ensuite le vocabulaire général puis le vocabulaire technique. L'utilisateur dispose d'un système-expert qui facilite le codage des mots qu'il souhaite ajouter dans le dictionnaire. On considère que 5000 entrées couvrent 90% du vocabulaire employé dans un texte général, pour une langue indo-européenne. Un dictionnaire de 100 000 termes aurait surtout pour inconvénient de multiplier les ambiguïtés et d'accroître considérablement les besoins en capacités de stockage.

Appliquant le principe de "vision globale", il traduit phrase par phrase et dispose pour chaque couple de langues, de dictionnaires monolingues et d'un dictionnaire de transfert.

Saisie du texte

S'il n'est pas livré sur un support informatique, le texte source peut être tapé au clavier ou saisi par un logiciel de reconnaissance optique (OCR). Tout ce qui concerne la mise en forme et le formatage est extrait du texte source. Ce détail est important. On constate en effet que 60% seulement des pages de documentation technique sont effectivement à traduire. Le texte est transmis à l'interpréteur Lisp qui replacera la traduction dans le masque de la page.

Analyse

L'analyse de l'allemand est fondée sur une grammaire syntagmatique indépendante du contexte, complétée par un ensemble de procédures capables de sélectionner les transformations. L'analyse de l'anglais, par contre, s'inspire plutôt d'une grammaire syntagmatique généralisée sans utiliser les transformations. L'analyse est distincte du transfert et le système peut être considéré comme multilingual dans le sens où les résultats de l'analyse peuvent être exploités pour le transfert et la synthèse dans plusieurs langues cibles. (Expérimentation sur le chinois et l'espagnol, tout comme sur le couple anglais-allemand). On peut citer également le projet lancé par SIEMENS et le gouvernement belge en 1985, (université Catholique de Louvain, universités de Mons et de Liège) sur les couples néerlandais-français et français-néerlandais.

Le système examine la phrase de la gauche vers la droite et analyse chaque mot d'un point de vue lexical. Il applique ensuite les règles de grammaire. En se basant sur un indice de probabilité affecté selon différents critères, il sélectionne la règle qui produira l'interprétation de la phrase la plus vraisemblable. Après avoir interprété tous les éléments de la phrase et défini leurs relations, il reconstitue les syntagmes. Une fois que toutes les règles de grammaire ont été appliquées et que les caractéristiques morphologiques, syntaxiques et sémantiques de chaque mot ont été définies, le système construit une structure arborescente qui illustre les relations syntaxiques. Les informations apportées par le dictionnaire et les règles appliquées sont associées a chaque noeud de l'arbre. Elles sont indépendantes de la langue cible. Cette étape consomme énormément de capacité mémoire (120 MB requis par le système).

Transfert

Deux composantes, les règles de la grammaire de transfert et les entrées du dictionnaire de transfert interviennent simultanément dans un processus descendant qui étudie les scores associés aux différents arbres construits lors de la phase d'analyse.

Ce processus est contrôlé par les règles de transfert dont chacune est le plus souvent associée aux règles de grammaire impliquées dans l'analyse de départ. Si une grammaire générale de tansfert est alors inutile pour déterminer la règle à appliquer, elle est cependant consultée pour la traduction des parties de phrases. La concomitance des transferts lexical et structural implique leur interaction. Les entrées du dictionnaire de transfert peuvent préciser le contexte syntaxique et/ou sémantique qui les validera. L'arbre qui a été obtenu lors de l'étape d'analyse est transformé en une structure correspondante dans la langue cible.

Génération

Le module de génération part de l'arbre ainsi obtenu pour générer les phrases cibles, conformément aux règles grammaticales, lexicales et syntaxiques. METAL peut, dans certains cas, résoudre des problèmes d'anaphore en partant d'un pronom et en effectuant une recherche dans la phrase précédente. Il peut également lever des ambiguïtés en ajoutant des attributs sémantiques aux entrées du lexique utilisé par le système lors des phases d'analyse et de traduction.

Résultats

La post-édition est effectuée sur un réseau de PC connectés à l'interpréteur Lisp. La traduction brute peut être présentée dans le format du texte source ou dans un format spécifique proposant le texte source en regard du texte cible, pour comparaison.

Pour améliorer le système, la laboratoire d'Austin a mis au point plusieurs utilitaires :

- un traitement de texte qui permet de conserver la mise en page du document d'entrée pour le formatage de la traduction.

- un système de gestion de base de données pour les entrées du dictionnaire et des règles de grammaire

- un système de validation pour éliminer les erreurs que pourraient renfermer les dictionnaires et les règles de grammaire.

- Pour le vocabulaire technique, et lié au domaine que privilégie METAL, un module nommé "Data Processing" qui introduit des subdivisions telles que le hardware, le sofware... Le traducteur peut alors demander au système, avant le processus de traduction, d'accorder une priorité à la subdivision concernée. Le mot *Fehler* sera alors traduit par *fault* (hardware), *error* (software), *defect* (technique courant), sinon *mistake*. Le traducteur pourrait créer d'autres types de subdivisions qui tiendraient compte par exemple des différences de terminologie pour l'espagnol d'Amérique du sud et le castillan. Le système traduirait alors correctement *computer* par *computadora* ou *ordenator*.

Système complet de Traduction Automatique, il est plus particulièrement destiné aux textes techniques (informatique et télécommunication) et fonctionne sur un interpréteur Lisp (Symbolics série 36) depuis qu'il a été traduit du Fortran en Lisp. La post-édition peut être effectuée sur des PC en réseau. Sa vitesse de traduction est d'un mot par seconde. La traduction est correcte pour 50% des phrases. Le dictionnaire contient 15000 entrées.

TRANSLATING USING METAL

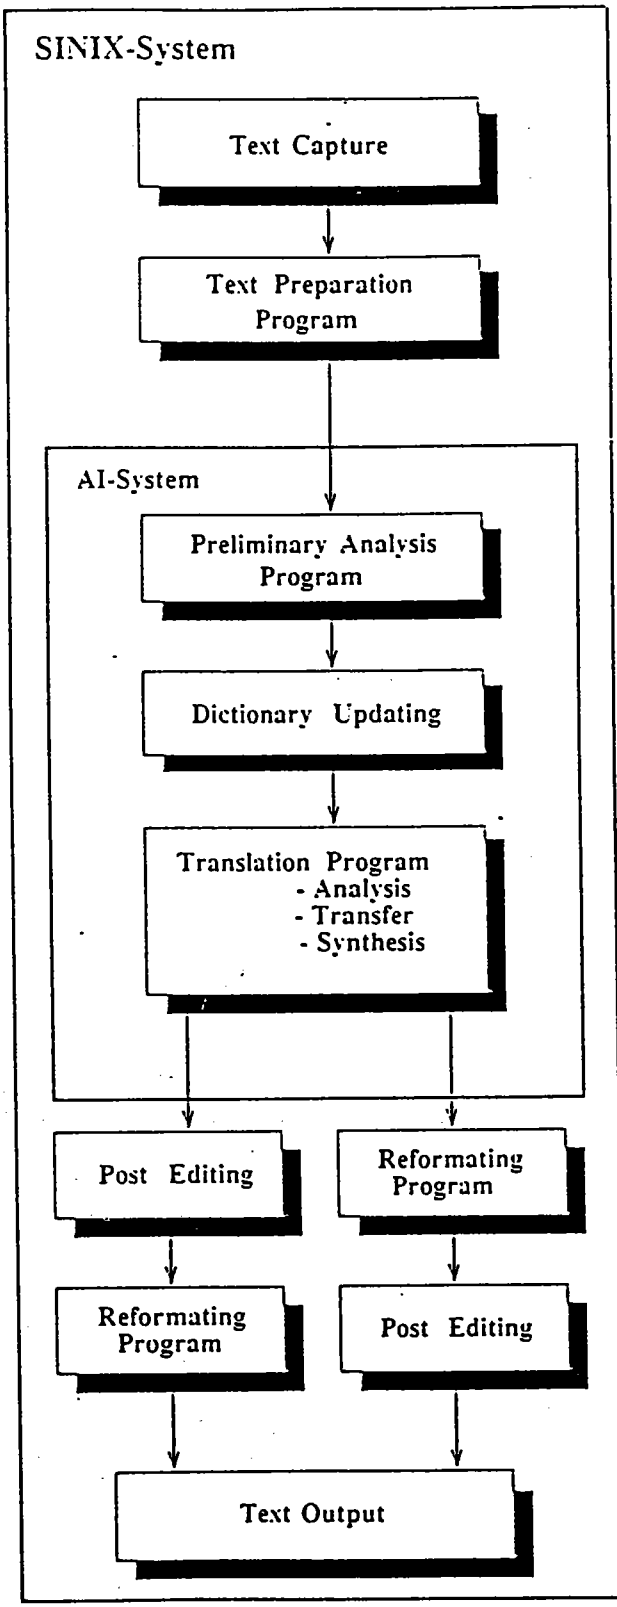

Text Input
- Text transfer via networks or data carriers (diskette. tape. scanner)

Text Formats
- Separation of text and formatting code
- Treatment of special formats (figures. tables)

Dictionary
- Check against dictionary
- Interactive expert system

Translation
- Machine translation

Post Editing
- Combining of text and formatting codes
- Correction of translated text and format
- Text system
- Printer
- Type setting

Schéma extrait de *IESNEWS*, (ESPRIT Information Exchange System), Issue n° 25, December 1989, publication de la DGXIII, Communautés Européennes, p. 12

Exemple de traduction extrait de W. BENNETT, J. SLOCUM : "The LRC Machine Translation System" in *Machine Translation Systems*, Studies in Natural Language Processing, Cambridge University Press, 1988, pp. 135-140

Einteilung des Plattenspeichers

Blockstruktur

Die kleinste adressierbare Informationseinheit ist ein Block = 1 Sektor. Zu jedem Block gehoert ein Header. Der Header enthaelt die gesamte Adresse, sowie Angaben ueber den Zustand des Blockes (Benutzbarkeit!). Zur Sicherung der Header-Information und der Daten befindet sich am Ende des Headers und des Datenfeldes ein Pruefzeichen von 16 Bit.

Vor dem Headerfeld befindet sich eine Praeambel von 42 Byte Laenge fuer den Ausgleich aller Toleranzen.

Vor dem Datenfeld befindet sich eine Praeambel von 5 Byte Laenge zur Aufsynchronisierung der Leseverstaerker. Vor und hinter dem Datenfeld befindet sich eine Luecke. Die Luecken sind aus folgenden Gruenden notwendig:

Luecke 1: 56 Bit wegen Schreib-Loesch-Kopfabstand. Zu Beginn der Daten-Schreiboperation muss gewaehrleistet sein, dass der Loeschkopf den Header nicht zerstoeren kann.

Luecke 2: 316 Bit im Normalmodus wegen der Toleranzen in der Umdrehungsgeschwindigkeit. Es muss die Moeglichkeit beruecksichtigt werden, dass das Schreiben des Blockes (Header + Datenfeld) an der unteren und oberen Grenze der Umdrehungsgeschwindigkeit erfolgen kann. Im Spezialmodus wird diese Luecke wegen der kleineren Bloecke 1340 Bit lang.

Division of disk storage

Block structure

The smallest addressable information unit is a block = 1 sector. A header is part of every block. The header includes the entire address, sowie specifications about the state of the block (usability!). A check character of 16 bits is found for the saving of the header information and the data at the end of the header and the data field.

A preamble of 42 byte length for the adjustment of all tolerances is found in front of the header field.

A preamble of 5 byte length is found in front of the data field for the synchronization of the read amplifier. A gap is found in front of and behind the data field. The gaps are necessary from the following reasons:

Gap 1: 56 Bit because of distance between write and erase heads. At the beginning of the data write operation it must be guaranteed, that the erase head can not destroy the header.

Gap 2: 316 Bit in the normal mode because of the tolerances in the rotational speed. The possibility must be considered that writing the block (header + data field) at the lower and upper limit/boundary of the rotational speed can occur. This gap becomes 1340 bits long in special mode because of the smaller blocks.

Am Ende des Header- und Datenfeldes befindet sich 1 Postambel von 8 Bit Laenge.

Spurstruktur

Eine Spur wird eingeteilt in 4 bzw. 8 Sektoren. Die Unterteilung der Spur in Sektoren erfolgt durch Index- und Sektormarken.

Die Indexmarke wird magnetisch durch einen Schlitz auf der untersten Platte des Plattenstapels erkannt und dient als allgemeiner Bezugspunkt fuer den Aufbau der Spurstruktur. Vom Indexpunkt ausgehend wird die Spur mit einem eigens dafuer vorgesehenen Dienstprogramm (oder Simulator!) mit Headern beschrieben. Die Bitzahl fuer das Datenfeld wird so bemessen, dass auch bei unguenstiger Drehzahl (= 2448 U/min) immer noch 4 bzw. 8 vollstaendige Bloecke Platz finden. (Siehe Abschnitt 4.1 Luecke 2). Je nachdem bei welcher Geschwindigkeit die Spur beschrieben wird, entsteht zwischen Ende des Datenfeldes und Indexmarke bzw. Sektormarke eine mehr oder weniger grosse Luecke.

Sektormarkierung

Die Sektormarke wird ebenso wie die Indexmarke von der Schlitzplatte, die sich als Bodenplatte an jedem Plattenstapel befindet, magnetisch abgenommen. Im Handel werden Plattenstapel mit 32 und mit 20 Schlitzen angeboten. Im vorliegenden Fall soll der Plattenstapel mit 20 Schlitzen beim WSP 411 und mit 32 Schlitzen beim WSP 414 verwendet werden. Eine Maske, dargestellt durch einen Zaehler blendet aus den 20 bzw. 32 Sektormarken 4 bzw. 8 aus, so dass 4 bzw. 8 gleich grosse Sektoren entstehen. Die Maske bzw. der Zaehler wird von der Herstellerfirma (CDS) in jeden Wechselplattenspeicher fest eingebaut.

The 1 postamble of 8 bit length is found at the end of the header and data field.

Track structure

A track is divided into 4 and/or 8 sectors. The subdivision of the track into sectors occurs through index label and sector marks.

The index label is recognized magnetically by a slot on the lowest disk of the disk pack and is used for the track structure as the general reference point for establishing. By the index point, the track with a utility program designated especially for that (or simulator!) is described with headers. The number of bits for the data field is calculated then that always still 4 and/or 8 complete blocks do also find space with unfavorable rotational speed/number of revolutions (= 2448 r.p.m.s). (See section 4.1 gaps 2.) Depending on with which speed the track is described, a more or less large gap occurs between the end of the data field and index label and/or sector mark.

Sector marker

Likewise the index label is read in the sector mark as by the slot disk which is found as a bottom disk at every disk pack magnetically. The disk packs with 32 and with 20 slotting are offered on the market. The disk pack should be used in this case with the 20 slots with the WSP 411 and with the 32 slots with the WSP 414.

A mask, represented through a counter masks out 4 and/or 8 from the 20 and/or 32 sector marks so that large sectors result similar to 4 and/or 8. The mask and/or the counter is incorporated by the Herstellerfirma (CDS) into every removable disk storage.

Exemples présentés par Monsieur le Professeur **BOURQUIN** dans le cadre de ses séminaires de D.E.A. :

METAL T54 11 MARS 1982 16H 41MN 14S

LANGUES DE TRAITEMENT: ANG-FRA

-- TEXTE ORIGINE --

for all pairs of materials a coating of the contact materials with Celloseel= lowered the corrosion current density.

-- TEXTE TRADUIT --

----- (TRADUCTION DU 11 MARS 1982 16H 34MN 24S) -----
VERSIONS : (A : 2/03/82 ; T : 8/03/82 ; G : 5/03/82)

pour touts paires de materiaux un revetement des materiaux de contact avec Celloseel a abaisse la densite du courant de corrosion.

METAL T55 11 MARS 1982 16H 48MN 30

LANGUES DE TRAITEMENT: ANG-FRA

-- TEXTE ORIGINE --

previously abstracted from original as item 7704-64-0108Y.

-- TEXTE TRADUIT --

----- (TRADUCTION DU 11 MARS 1982 16H 47MN 52S) -----
VERSIONS : (A : 2/03/82 ; T : 8/03/82 ; G : 5/03/82)

precedemment resumees a partir original comme l'article <7704-64-0103Y>.

METAL T56 11 MARS 1982 16H 56MN 4C

LANGUES DE TRAITEMENT: ANG-FRA

-- TEXTE ORIGINE --

the effect of the thickness of the Al coating on the corrosion and H absorption of steel sheet (1-3 mm) and steel wire (0.5 mm diam) was studied .

-- TEXTE TRADUIT --

----- (TRADUCTION DU 11 MARS 1982 16H 54MN 23S) -----
VERSIONS : (A : 2/03/82 ; T : 8/03/82 ; G : 5/03/82)

l'effet de l'épaisseur du revetement de Al sur la corrosion et absorption de H de la tole d'acier (<1-3> mm) et on a etudie le cable d'acier (<0.5> mm de diam).

METAL T58 11 MARS 1982 17H 26MN 38S

-LANGUES DE TRAITEMENT: ANG-FRA

-- TEXTE ORIGINE --

for thicker coatings the samples behaved like pure Al.

-- TEXTE TRADUIT --

----- (TRADUCTION DU 11 MARS 1982 17H 25MN 43S) -----
VERSIONS : (A : 2/03/82 ; T : 8/03/82 ; G : 5/03/82)

pour des revetements plus epais les echantillons se sont comportes comme le Al pur.

METAL T59 11 MARS 1982 17H 53MN 45

LANGUES DE TRAITEMENT: ANG-FRA

-- TEXTE ORIGINE --

electron diffraction studies showed that Fe spinel FeAl2O4 is formed on the steel surface.

-- TEXTE TRADUIT --

----- (TRADUCTION DU 11 MARS 1982 17H 49MN 01S) -----
VERSIONS : (A : 2/03/82 ; T : 8/03/82 ; G : 5/03/82)

diffraction d'electron etudie que spinelle de Fe FeAl2O4 est formee sur la surface d'acier.

METAL T60 11 MARS 1982 17H 59MN 12

LANGUES DE TRAITEMENT: ANG-FRA

-- TEXTE ORIGINE --

the adhesion of the Al coating is high and is retained almost up to the complete destruction of the sample.

-- TEXTE TRADUIT --

----- (TRADUCTION DU 11 MARS 1982 17H 58MN 09S) -----
VERSIONS : (A : 2/03/82 ; T : 8/03/82 ; G : 5/03/82)

l'adherence du revetement de Al est elevee et est ete conservee presque jusqu'a la destruction complete de l'echantillon.

METAL T62 11 MARS 1982 18H 14MN

LANGUES DE TRAITEMENT: ANG-FRA

-- TEXTE ORIGINE --

the corrosion and the diffusion of H in H2SO4 decreases greatly as the coating thickness is increased.

-- TEXTE TRADUIT --

----- (TRADUCTION DU 11 MARS 1982 18H 13MN 50S) -----
VERSIONS : (A : 2/03/82 ; T : 8/03/82 ; G : 5/03/82)

la corrosion et la diffusion de H dans H2So4 diminue considerablement comme on augmente l'epaisseur de revetement.

METAL T63 11 MARS 1982 18H 20MN

LANGUES DE TRAITEMENT: ANG-FRA

-- TEXTE ORIGINE --

the purpose of this continuing investigation was to measure limiting C diffusion current densities as a function of seawater velocity, to study cathodic kinetics on 5456-H117 Al alloy as a function of velocity and to conduct constant potential tests at more active potentials than -0.9 VSCE.

-- TEXTE TRADUIT --

----- (TRADUCTION DU 11 MARS 1982 18H 19MN 58S) -----
VERSIONS : (A : 2/03/82 ; T : 8/03/82 ; G : 5/03/82)

le but de cette recherche en cours etait pour mesurer les densites du courant limite de diffusion de C comme une fonction de la vitesse de l'eau de mer, pour etudier la cinetique cathodiqu sur l'alliage d'Al 5456-H117 comme une fonction de la vitesse et pour mener les tests constants de potentiel a des potentiels plus actifs que' <-0.9> VSCE.

METAL T64 11 MARS 1982 18H 24MN 30S

LANGUES DE TRAITEMENT: ANG-FRA

-- TEXTE ORIGINE --

finally, a model was proposed to explain the observations from this and previous studies.

-- TEXTE TRADUIT --

----- (TRADUCTION DU 11 MARS 1982 18H 24MN 13S) =====
VERSIONS : (A : 2/03/82 ; T : 8/03/82 ; G : 5/03/82)

finalement, on a propose un modele pour expliquer les observations a partir ceci et etudes precedentes.

METAL T65 11 MARS 1982 18H 29MN 24S

LANGUES DE TRAITEMENT: ANG-FRA

-- TEXTE ORIGINE --

the corrosion of some steels and Al alloys in ammoniacal solutions (50-200 g/l NH3) was investigated.

-- TEXTE TRADUIT --

----- (TRADUCTION DU 11 MARS 1982 18H 29MN 06S) -----
VERSIONS : (A : 2/03/82 ; T : 8/03/82 ; G : 5/03/82)

on a etudie la corrosion de quelques aciers et des alliages de Al dans des solutions ammoniacales (<50-200> g-l de NH3).

METAL T67 11 MARS 1982 18H 37MN 15

LANGUES DE TRAITEMENT: ANG-FRA

-- TEXTE ORIGINE --

even low concentrations (0.1 percent) of NaOH increase the corrosion rate.

-- TEXTE TRADUIT --

----- (TRADUCTION DU 11 MARS 1982 18H 36MN 19S) -----
VERSIONS : (A : 2/03/82 ; T : 8/03/82 ; G : 5/03/82)

meme des basses concentrations (<0.1> pour cent) de NaOH augmentent le taux de corrosion.

METAL T66 11 MARS 1982 18H 33MN 3.

LANGUES DE TRAITEMENT: ANG-FRA

-- TEXTE ORIGINE --

initially, the Al alloys are strongly corroded by ammoniacal solutions, but the corrosion is stopped in time.

-- TEXTE TRADUIT --

----- (TRADUCTION DU 11 MARS 1982 18H 33MN 12S) -----
VERSIONS : (A : 2/03/82 ; T : 8/03/82 ; G : 5/03/82)

au depart, on corrode les alliages de Al fortement par ces solutions ammoniacales, mais on arrete la corrosion dans le temps.

2.3.3.2.6 PENSEE[1]

Le système a été créé et commercialisé par la firme japonaise OKI, en 1986. Il fonctionne sur le couple japonais-anglais. Une version anglais-japonais est en développement. Le logiciel est écrit en langage C et tourne sur un ordinateur MC-68010 ou MC-68020C (système d'exploitation UNI PLUS+). Le système est interactif et réalise une traduction automatique à la vitesse de 4 000 mots/heure. Une étape de post-édition est nécessaire.

2.3.3.2.7 PIVOT[1]

Destiné à devenir un système multilingual, PIVOT a été développé par la firme japonaise NEC et commercialisé en 1986 pour les couples anglais-japonais et japonais-anglais. Sur le principe de l'utilisation d'un language pivot, le système utilise des techniques de l'Intelligence Artificielle et fonctionne en mode interactif pour réaliser une traduction totalement automatique. Le dictionnaire contient 40 000 entrées pour le japonais, 53 000 pour l'anglais et 400 000 termes techniques. Il est écrit en language C et fonctionne sur un microordinateur ACOS 4 ou sur un gros calculateur (système d'exploitation ACOS 4). Les textes traités sont techniques ou scientifiques.

2.3.3.2.8 SANYO[1]

Développé par la firme japonaise SANYO et commercialisé sous le nom de SWP-7800, il fonctionne sur le couple japonais-anglais. Construit sur le modèle des systèmes de transfert, il est écrit en language C, tourne sur un Intel 80186 (système d'exploitation IRMX), nécessite une phase de pré- et de post-édition et traduit à la vitesse de 3 500 mots/heure à l'aide d'un dictionnaire de 55 000 entrées.

2.3.3.2.9 SYSTRAN[2,3,4,5]

SYSTRAN est vraisemblablement le plus ancien des systèmes de traduction automatique en fonctionnement. Il faut cependant souligner les efforts déployés pour l'améliorer et le développer. Ses origines remontent au projet GAT de l'université de Georgetown (2.3.2.1).
Les améliorations concernent la partie logicielle avec une modularité accrue et l'abandon d'une méthode de traduction directe pour une approche de transfert.
SYSTRAN est le système le plus répandu (sur gros calculateur)[6]. L'U.S. Air Force l'utilise depuis 1970 à Dayton, Ohio, (100 000 pages traduites par an depuis 1987 sur le couple russe-anglais). Depuis 1989, il traduit des brevets (russe-anglais). General Motors Canada l'utilise depuis longtemps pour l'anglais-français et depuis peu pour l'anglais-allemand et l'anglais-espagnol, Xerox pour la traduction de manuels techniques (50 000 pages/an anglais-français, anglais-espagnol, anglais-portugais, anglais-italien,

---

(1) S. MELI : "Informationsmarkt der maschinellen Übersetzung" in *Terminologie et Traduction*, Commission des Communautés Européennes, n°3, 1989, pp. 83-84

(2) S. TRABULSI : "Le système SYSTRAN" in *TAO*, Observatoire des Industries de la langue, DAICADIF, 1989, pp. 15-34

(3) Documents de la société GACHOT

(4) Proceedings of the World SYSTRAN Conference, Luxembourg, février 1986, published by the Commission of the European Communities

(5) G. VAN SLYPE : "Description du système de Traduction Automatique SYSTRAN de la Commission des Communautés Européennes" in *Documentaliste*, vol. 16, n°4, 1979, pp. 150-159

(6) W. HUTCHINS : "Recents Developments in Machine Translation. A Review of the Last Five Years" in : *New Directions in Machine Translation*, Conference Proceedings, Budapest, 18-19/08/1988

anglais-allemand, l'OTAN à Bruxelles, le Centre de Recherche nucléaire à Karlsruhe (français-anglais), la Deutsche Bundesbahn et d'autres grandes sociétés comme Dornier, Festo, l'Agence Internationale de l'Energie Atomique (Vienne), l'Aerospatiale pour des manuels de documentation aéronautique (anglais-français, français-anglais).
Nous ne retracerons pas l'histoire de SYSTRAN mais rappellerons qu'en février 1976 la Communauté Européenne, grande consommatrice de traduction, a décidé d'acquérir une version de SYSTRAN (fonctionnant sur gros calculateur IBM) pour l'évaluer et s'en équiper. Les résultats ont été décevants mais l'expérience a été poursuivie en espérant que l'ajout de dictionnaires améliorerait les performances du système au point de justifier son installation. Les versions français-anglais (1978) et anglais-italien (1979) furent à leur tour installées en 1981.
Deux couples de langues supplémentaires anglais-français et français-allemand ont été créés en 1982. La Communauté l'utilise à Luxembourg, mais les traductions réalisées n'ont représenté en 1987 que 2% de l'ensemble des traductions, l'avantage essentiel résidant dans l'élargissement considérable des lexiques. Le fait que les textes soumis au système soient au préalable sélectionnés explique le faible pourcentage, il est probable qu'il augmentera si les traducteurs acceptent de rédiger la version brute que leur propose la machine, tant il est prévisible que le futur système (EUROTRA) n'est pas près de lui succéder.

Depuis 1986, les sociétés américaines (LATSEC et WTC aux Etats-Unis) et européennes (**Systran Institute** en Allemagne et sa filière au Luxembourg) qui participaient à l'exploitation de SYSTRAN ont été rachetées par le groupe **Gachot** qui est chargé d'assurer la cohérence de ses développements (Au Japon, c'est la société IONA), et a conclu un accord de coopération avec la Commission des Communautés Européennes. Cette dernière consacre d'ailleurs un budget très important au développement des dictionnaires pour les langues européennes (32 personnes de la CCE et de la société Informalux). Des accords de développement ont égale- ment été conclus pour l'extension des dictionnaires avec Rank Xerox et General Motors.

SYSTRAN a été développé sur des ordinateurs IBM, selon le principe d'une absence de limitation en matière de temps calcul et de capacité de stockage. Les clients devaient posséder de gros ordinateurs et construire les interfaces en amont et en aval du système. La société Gachot a comblé le manque de convivialité inhérent aux applications lourdes en conjuguant les techniques de l'informatique et de la télématique. Le groupe a créé un serveur SYSTRAN qui permet à l'utilisateur de communiquer avec le système à partir de son microordinateur ou via le Minitel par le réseau commuté (par TRANSPAC).
SYSTRAN est le seul système capable en principe de traduire des textes de toute sorte, en raison de ses dictionnaires nombreux et constamment élargis. Le système dispose de 500 catégories sémantiques dans une structure hiérarchisée, pour la résolution des ambiguïtés.
SYSTRAN est un système de première génération en mutation. Le classement par "génération" est peu significatif[1] . Cela signifie qu'il prenait un certain nombre de décisions définitives à chaque pas de l'analyse, contrairement "au principe de base heuristique récursif" des systèmes de seconde génération. D'un point de vue linguistique, le caractère linéaire de son principe facilitera les transformations tant au niveau des programmes qu'au niveau des dictionnaires. On peut ajouter facilement des modules ici et là, qu'il s'agisse d'une liste de règles lexicales (diction naires) pour améliofer la qualité de la traduction, ou d'un module de traitement complémentaire pour le système de base.

---

(1) P. TOMA : "SYSTRAN : Ein maschinelles Übersetzungssystem der 3. Generation" in *Sprache und Datenverarbeitung*, 1/1977, pp. 38- 45, Niemeyer, Tübingen, 1977

Documentation SYSTRAN International :

SYSTRAN
INTERNATIONAL

Traduction automatique sur ordinateur

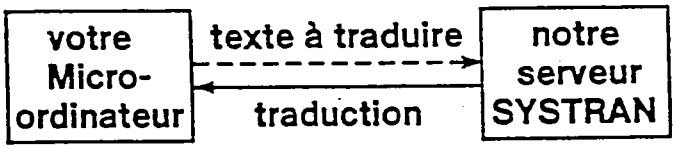

10 pages - 10 minutes

- **Traduisez sans contrainte** vos textes techniques, documentations spécialisées, notices explicatives, etc., **dans les langues suivantes :**

Français
- → Anglais
- → Italien
- → Néerlandais

Anglais
- → Français
- → Allemand
- → Néerlandais
- → Italien
- → Espagnol
- → Portugais
- → Arabe

Allemand
- → Anglais

Espagnol
- → Anglais

Russe
- → Anglais

- **Nos références :**
  U.S. Air Force, C.E.E., A.T.T., Rank Xerox...

- **Votre contact :** 33 1 39 89 90 11

SYSTRAN INTERNATIONAL
Groupe GACHOT
26 bis, avenue de Paris
95230 SOISY-sous-MONTMORENCY - FRANCE
Télex : 606754 F - Téléfax : 33 1 39 89 49 34

NOUS TRADUISONS L'AVENIR

Le schéma suivant réunit les composants du système :

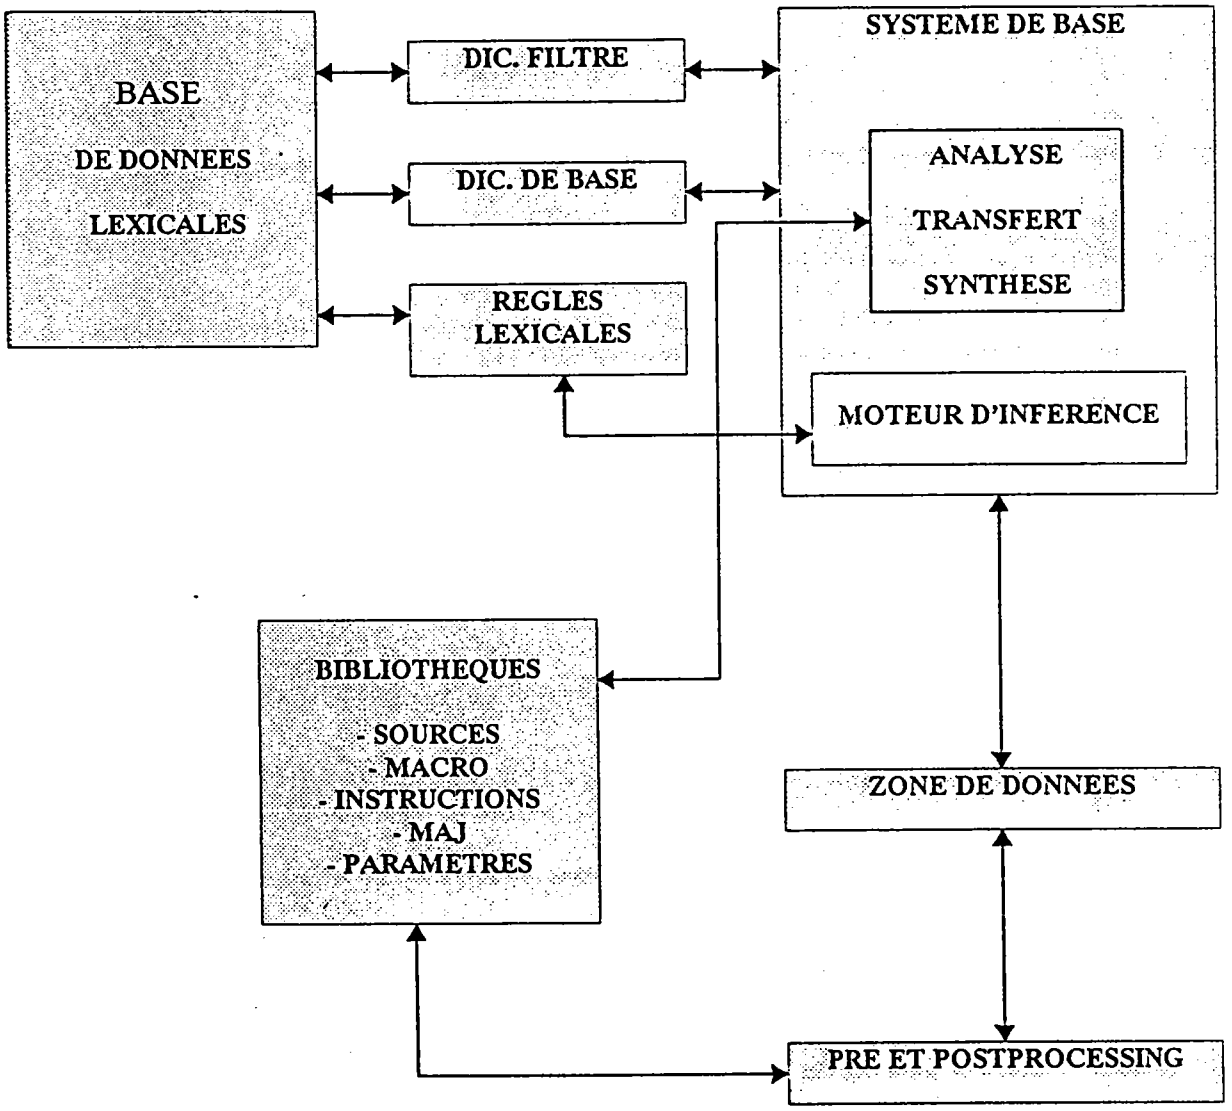

Le noyau du système rassemble les programmes responsables des étapes classiques : analyse, transfert et synthèse. Ces programmes regroupent des sous-programmes ayant chacun une rôle précis. Ils sont écrits dans une variante du Fortran inspirée de l'Assembleur et adaptée aux exigences de la linguistique. Chaque couple de langues correspond à un ensemble de 130 000 lignes de programmation (dont les 5/6 pour l'analyse) gérées par un language de contrôle qui enchaîne les traitements et assure la continuité des tâches puisqu'il est capable d'interrompre l'exécution lorsqu'il rencontre une anomalie.

Les dictionnaires (30 Mo dans un format machine pour un couple de langues) constituent un ensemble qui fonctionne à la manière d'un système expert. Les règles lexicales sont classées sur douze niveaux, dans une base de connaissances, sous la forme de groupes d'opérateurs. Chaque niveau est subdivisé en seize niveaux de priorité. Le tout est piloté par un moteur d'inférence indépendant des langues sources et cibles. Ce moteur décide d'appliquer ou non chaque règle lexicale. (Pour un texte de 100 000

mots, il sélectionne dans un dictionnaire de 100 000 règles, l'ensemble des règles qui seront prise en compte, en moins de 10 minutes).
Les dictionnaires sont de deux sortes :

- le dictionnaire des mots de base :

Chaque mot de la langue source est accompagné d'une description complète morphologique, grammaticale, syntaxique et sémantique. On lui associe une traduction de base dans la langue cible avec l'ensemble des informations grammaticales nécessaires à la synthèse.
Les homographes constituent autant d'entrées distinctes. La polysémie n'est abordée que plus tard. L'importance de l'analyse syntaxique traduit l'influence des théories de N. CHOMSKY. Il fallut très vite ajouter des informations qui ne furent en fait que des marqueurs sémio-syntaxiques. La sémantique n'a été introduite que beaucoup plus tard. On ne peut prétendre à une traduction correcte avec un dictionnaire qui ne donne qu'un sens par mot.

Les dictionnaires de contexte :

Ces dictionnaires spécifiques sont utilisés à diverses étapes du traitement dans le but de modifier la traduction des mots en fonction de leur contexte.

- ***Le dictionnaire idiomatique*** permet d'assimiler une expression idiomatique invariable à une seule unité qui sera analysée par le dictionnaire général comme une locution.
- ***Le dictionnaire des inter-relations fortes*** limite les relations à un groupe nominal.

ex. : *Hydraulic brake* --> *frein hydraulique*
Hydraulic brake valve --> *soupape de frein hydraulique*
(non *soupape hydraulique de frein*)

- ***Le dictionnaire des groupes nominaux*** fonctionne comme le dictionnaire précédent mais concerne les groupes dont la traduction ne se ramène pas à la juxtaposition des traductions de ses composants.

ex. : *pomme de terre*

- ***Le dictionnaire homographique*** rassemble les exceptions aux règles grammaticales générales.

ex. : si verbe + nom --> le nom est précédé d'un article.
exception : prendre note

- ***Le dictionnaire analytique*** est en fait constitué d'une série de dictionnaires qui sont utilisés tout au long de l'analyse syntaxique et qui contiennent les exceptions aux règles grammaticales.

- ***Le dictionnaire conditionnel*** n'intervient qu'au moment du transfert pour le choix définitif du mot, en faisant intervenir des relations sémantiques et syntaxiques sans aucune contrainte de contiguïté. La puissance de ce dictionnaire est sans limites, si ce n'est le volume des données que cela peut représenter et l'aspect "bricolage" sous-jacent. (400 expressions ont été codées pour distinguer *le pétrole* et *l'huile* dans le mot *oil*).

Un troisième ensemble regroupe **les bibliothèques** de programmes sources, d'utilitaires, de dictionnaires sources, de bases de données, de programmes d'interface avec les différents types de périphériques (530 bibliothèques au total, 5000 MB !).

Les logiciels comprennent en fait :

- le logiciel de traduction
- le logiciel de création et de mise à jour des dictionnaires
- les utilitaires

Les programmes qui assurent la création et la mise à jour des dictionnaires , les modules qui contrôlent le déroulement du processus de traduction et les utilitaires sont écrits en Assembleur. Ils sont indépendants des langues traitées.

Les programmes qui analysent la langue source et assurent la synthèse dans la langue cible sont rédigés dans le macro-language SYSTRAN qui permet de coder plus simplement sous une forme symbolique les règles syntaxiques et sémantiques. Ils sont spécifiques à chaque couple de langues.

En moyenne, selon le couple de langues, un mot traduit implique 25 à 30 000 opérations. On peut résumer le processus de traitement de la façon suivante :

Etape 1 : Lecture du texte source et consultation des dictionnaires

le programme MTST lit le texte à traduire, le convertit à l'aide des caractères héxadécimaux du standard SYSTRAN, stocke chaque phrase dans un enregistrement de longueur variable, enregistre les données concernant la mise en forme et le formatage pour les restituer lors de l'impression de la traduction.

Le programme LOADTXT charge les dictionnaires d'unités fréquentes et les listes d'idiotismes en mémoire centrale, puis le texte, phrase par phrase. Il compare très rapidement chaque mot de la phrase avec les entrées des dictionnaires (méthode binaire, binary search). S'il y a concordance avec un mot ou une racine de haute fréquence, il ajoute un code au mot du texte (qui introduit de ce fait les informations grammaticales correspondantes en mémoire centrale). Si c'est un expression idiomatique, il ajoute le code au premier mot de l'idiotisme. Il en profite pour numéroter les mots du texte, traiter les mots à trait d'union et trier alphabétiquement tous les mots qui n'ont pas été reconnus. (Cet ordre correspond au type de classement du dictionnaire général). Ce travail est effectué à une vitesse de 20 000 mots/minute.

Le programme MDL (Main Dictionary Lookup) charge en mémoire centrale, bloc par bloc, le dictionnaire et le texte trié des mots non fréquents et n'appartenant pas à une expression idiomatique pour les comparer (vitesse de 4 000 mots/minute). Les mots y sont classés par ordre alphabétique et par racines. Figurent également dans ce dictionnaire, outre les informations grammaticales, les expressions techniques multitermes et les traductions dans la langue cible. S'il y a correspondance, il copie à côté du mot les informations grammaticales du dictionnaire et les traductions possibles. Après consultation du dictionnaire, il replace les mots dans l'ordre initial du texte (en reprenant les numéros d'ordre affectés par LOADTXT) à une vitesse de 10 000/minute.

La routine NFWRTN (Not Found Word Routine) examine les mots qui n'ont pas été trouvés dans le dictionnaire pour leur associer éventuellement un code, s'il s'agit d'un nombre, si la terminaison figure dans le fichier des désinences, si c'est une abréviation ou enfin un nom propre.

Pour un texte source de 140 000 mots :
- 40 000 mots sont reconnus lors du processus de comparaison avec le dictionnaire des mots courants et reçoivent un code (2 minutes 30 secondes de temps calcul).
- Les 100 000 mots restants sont triés alphabétiquement en 4 minutes.
- Recherche de ces mots et analyse morphologique (4 minutes).
- Rangement des mots dans l'ordre initial avec les informations afférentes (5 minutes).

Etape 2 : Analyse

le programme INITCALL charge et exécute les programmes de traduction responsables de l'analyse du texte source, du transfert, de la synthèse et de l'édition de la traduction.

le programme GETSENTN réserve une zone d'analyse de 16,8 Ko en mémoire centrale (105 mots de 160 caractères) et une zone complémentaire pour les homographes. Le texte est chargé, phrase par phrase dans la zone principale. Il reclasse dans l'ordre d'origine les mots à haute fréquence (auxquels LOADTXT a associé l'adresse des informations grammaticales dans la table des règles grammaticales) et les mots à basse fréquence (auxquels MDL a associé les informations grammaticales et les traductions possibles).

Le programme de résolution des homographes lit la phrase de la gauche vers la droite pour repérer les homographes. Lorsqu'il en localise un, il appelle la routine correspondant au type d'homographe, et l'étudie en examinant le contexte gauche et le contexte droit. En dernière extrémité, le programme retient la solution considérée comme la plus fréquente.

Le programme LSLOOKUP identifie les groupes de mots contigus qui forment une expression composée (expression LS, Limited Semantics). Chaque mot du texte, à ce stade, a été complété par un numéro d'identification propre à chaque mot et à ses flexions lors de la consultation du dictionnaire des unitermes. LSLOOKUP compare alors ces numéros d'identification à un fichier contenant les séquences de numéros constitutives d'expressions LS. S'il y a concordance, la traduction des mots de l'expression LS remplace la traduction qui avait été proposée par le dictionnaire des unitermes. Si les informations syntaxiques et sémantiques liées à l'expression LS ne correspondent pas aux informations fournies initialement par le dictionnaire des unitermes, elles les remplacent.

Le programme de délimitation des propositions (SP0, Stuctural Pass 0) lit la phrase pour localiser les mots susceptibles de délimiter une proposition (pronom relatif, conjonction de subordination, ponctuation). Il peut identifier 11 types de propositions subordonnées, incluses ou pas.
Nous empruntons à G. v. SLYPE l'exemple de la phrase anglaise suivante :

the parameters THAT affect the launch time will be given.

La routine cherche le premier verbe conjugué sur la droite de *THAT* --> *affect*. Elle cherche ensuite une virgule qui ne soit pas une virgule d'énumération mais n'en trouve pas. Elle cherche alors un verbe conjugué sur la gauche de *THAT* et n'en trouve pas (la proposition relative est donc incluse). Elle cherche un autre verbe sur la droite de *THAT* --> *will*. La routine cherche ensuite sur la gauche de *THAT* un sujet potentiel de la proposition principale, c'est à dire un nom ou un pronom qui ne soit pas introduit par une préposition --> *parameters*. Le mot qui précède le second verbe est un délimiteur --> *launch*. La proposition relative est *THAT affect the launch*. Les propositions sont numérotées et chacun de leurs constituants identifiés selon le type de la proposition.

Le programme d'identification des relations syntaxiques primaires (SP1, Structural Pass 1) lit la phrase de la droite vers la gauche en ignorant les propositions incluses pour les reprendre ultérieurement, et identifie 10 types de groupes syntaxiques. (le nom et ses modificateurs, le verbe et ses objets, le pronom relatif et ses antécédents...). Il positionne des pointeurs pour relier les modificateurs aux mots modifiés, les mots gouvernants aux mots gouvernés, en indiquant le type du groupe :

groupe verbe - objet direct	*Have a cigarette*
nom/ajectif+infinitif - infinitif	*the attempt to think clearly*
adverbe - adverbe/adjectif	*the extremely disagreeable Woman*

le programme identifie les mots qui fonctionnent comme des noms, associe aux verbes les informations relatives au temps, à la personne, aux auxiliaires, traite les degrés de l'adjectif.

Le programme d'identification des relations syntaxiques étendues (SP2, Structural Pass 2), pour l'anglais, parcourt la phrase de droite à gauche pour localiser les "AND", les "OR" et les virgules qui ne sont pas des délimiteurs de proposition. Il tente alors d'identifier les éléments susceptibles de constituer une énumération et positionne des pointeurs pour les relier.

Le programme d'identification du sujet et du prédicat (SP3, Structural Pass 3) lit les propositions en ignorant les incluses, cherche un verbe fini ou une énumération de verbes finis dans la proposition et positionne des pointeurs qui relient le premier mot de la proposition au premier verbe. Il recherche ensuite le sujet. S'il n'en trouve pas, le prédicat est marqué comme un verbe à l'impératif. Il relie enfin par pointeur, le sujet et le prédicat, le premier mot de la phrase et le sujet et recherche si le sujet ne fait pas partie d'une éventuelle énumération.

Le programme d'appartenance des prépositions (PREPPGM1) lit la phrase et recherche les prépositions puis les mots dont elles dépendent ou qui en dépendent. (possibilité de trouver un mot qui gouverne plusieurs prépositions).

Etape 3 : Le transfert

Le programme CLSLOOKUP reconnaît les expressions conditionnelles. Il s'agit alors d'utiliser les critères qui permettent de déterminer comment et sous quelles conditions les mots de l'expression seront traduits. (on compare les relations syntaxiques qui ont été déterminées entre les mots de l'expression avec les règles grammaticales qui sont intégrées dans le dictionnaire des expressions LS).

Le programme de traduction des prépositions (PREPPGM2) traduit les prépositions soit directement à partir du dictionnaire soit à partir des indications fournies par le dictionnaire pour les mots qui en dépendent ou dont elles dépendent.

Le programme de résolution des ambiguïtés sémantiques (LEXICAL) doit résoudre les ambiguïtés sémantiques restantes à l'aide de routines lexicales.

Etape 4 : La synthèse

Le programme de synthèse lit la phrase de gauche à droite et traduit chaque mot en utilisant les différents dictionnaires et des routines spécifiques à certaines parties du discours (pour le verbe, par exemple avec le français comme langue cible, , détermination de la personne, du nombre, du temps et du mode, choix de l'auxiliaire, respect des accords du participe....).
Le programme de réarrangement replace les adverbes, les adjectifs et les noms dans l'ordre correct pour la langue cible.

Etape 5: L'édition

Le programme d'impression de la traduction réalise la mise en page du texte traduit en reprenant les indications stockées lors de la première étape.

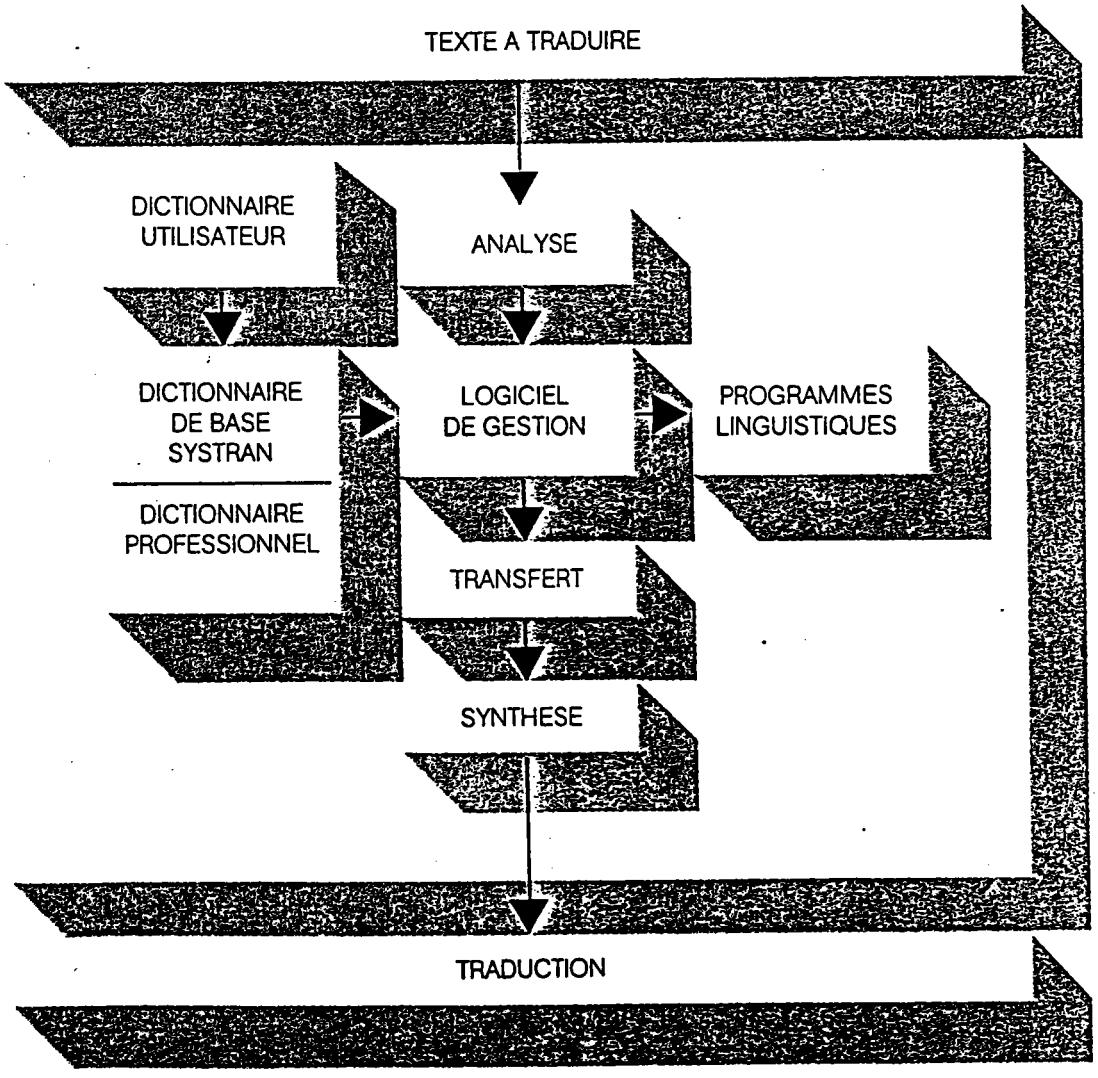

Exemples de traductions obtenues par SYSTRAN :

SOURCE (V 1)	CIBLE (V 2) ①
During its first ten years, the common agricultural policy has been mainly based on the common organization of the agricultural markets.	Pendant ses les dix premiers ans, la politique agricole commune principalement a été fondée sur l'organisation commune des marchés agricoles.
The common organization of the markets is thus based on three fundamental principles the validity of which has not been affected in any way by the accession of the three new Member States.	L'organisation commune des marchés est fondée ainsi sur trois principes fondamentaux la validité desquels n'a pas été affectée de quelque façon que ce soit par l'adhésion des trois nouveaux Etats membres.
The possibility that the US Environmental Protection Agency may ban the use of chemical sterilants for sterilizing packaging materials is mentioned, and consideration is given to the development of systems whereby packaging materials (e.g. plastics pouches) are sterilized by exposure to UV light.	On mentionne la possibilité que l'agence Etats-Unis de protection de l'environment peut interdire l'utilisation de stérilisants chimiques pour stériliser des matériaux de conditionnement, et on donne la considération au développement des systèmes par lequel des matériaux de conditionnement (par exemple poches plastiques) sont stérilisés par l'exposition à la lumière UV.
Proposal for a Council Regulation on a common measure for forestry in certain dry Mediterranean zones of the Community (submitted to the Council by the Commission).	Proposition pour un règlement du Conseil sur une mesure commune pour la sylviculture dans certaines zones méditerranéennes sèches de la Communauté (soumise au Conseil par la Commission).
The methods previously used for denitrification studies, involving isotopic studies (^{15}N and ^{13}N) and gas chromatography, were insensitive, laborious or affected by contamination by atmospheric N_2 (Yoshinari et al., 1977).	Les méthodes employées précédemment pour des études de denitrification, comportant les études isotopiques (15N et 13N) et la chromatographie en phase gazeuse, étaient insensibles, laborieuses ou affecté par la contamination par le N2 atmosphérique (Yoshinari et autres, 1977).

SOURCE (V 1)	CIBLE (V 2) ②
(c) the problem of the lost unity of the Community market, caused by monetary compensatory amounts and hindrances such as persistent obstacles to the free movement of certain products or to the specialization of agricultural areas in accordance with their relative advantages.	(c) le problème de l'unité perdue du marché communautaire, provoquée par des montants compensatoires et des obstacles monétaires tels que les obstacles persistants à la libre circulation de certains produits ou à la spécialisation des zones agricoles en conformité avec leurs avantages relatifs.
If, however, during a period of frequent changes in the state of international markets in agricultural produce, the Community were to be faced with surpluses, the maximum priority would be given to disposing of these surpluses on the internal market.	Si, cependant, pendant une période des changements fréquents dans l'état de marchés d'international dans des produits agricoles, la Communauté devait être confrontée par des excédents, la priorité maximum serait donné à éliminer ces excédents sur le marché intérieur.
Plantations in Cameroon comprise numerous aged coffee trees which must be regenerated either to increase the profitability of estates or diminish planted areas, while maintaining the overall production of the country at the same level.	Les plantations au Cameroun comportent les nombreux arbres âgés de café qui doivent être régénérés pour augmenter la rentabilité des domaines ou pour diminuer des régions plantées, tout en maintenant la production générale du pays au même niveau.
It has been necessary to analyse various market data, both on the supply and demand sides, in order to enable a decision to be taken in keeping with market conditions.	C'a été nécessaire d'analyser de différentes informations sur le marché, tous deux sur l'approvisionnement et des côtés de demande, pour permettre à une décision d'être pris en accord avec des conditions de marché.

SOURCE (V 1)	CIBLE (V 2) ③
Given the complexity of actual situations and the wide variety of instruments employed, the across-the-board instruments will first be examined, followed by the general guidelines concerning a number of products and, finally, the specific improvements proposed for the common organization of the principal markets.	Donné la complexité des situations réelles et la grande variété d'instruments utilisés, les instruments de à travers--panneau d'abord seront examinés, suivi ces lignes directrices générales au sujet d'un certain nombre de produits et, finalement, les améliorations spécifiques proposées pour l'organisation commune du principal vendent.
Constraints for moving sprinklers and pipes, and labour cost involved prove high when spray irrigation concerns large plots.	Les contraintes pour des arroseuses et des conduits mobiles, et le coût de la main-d'oeuvre en question s'avèrent que haut arrosera quand parcelles de terrain de soucis d'irrigation de grandes.
Undertakings which were still concerned with agricultural production on the formation of the EEC have gradually shifted to the production-processing area.	Les engagements qui encore ont été concernés par une production finale de l'agriculture sur la formation de la CEE ont décalé graduellement à la région de production-traitement.
On the supply side this has, for example, concerned the product, product quality and product developments by the agricultural undertaking concerned and by competitors' market force and stragegy, the potential in respect of basic materials and auxiliary materials and other equipment, suppliers' capacities, financing aspects and marketing methods.	Sur le côté d'approvisionnement ceci, par exemple, a concerné le produit, la qualité du produit et les développements de produit par l'engagement agricole concerné et par la force de marché des concurrents et stragegy, le potentiel en ce qui concerne des matières de base et les matières auxiliaires et d'autres équipement, capacités des fournisseurs, aspects de financement et méthodes de vente.
The relationship between the length of sarcomeres and the tenderness of meat has been well established since the initial observations of Locker (1960).	Le rapport entre la longueur des sarcomeres et la tendreté de la viande a été bien établi depuis les observations initiales de l'armoire (1960).

COMMISSION
DES COMMUNAUTÉS
EUROPÉENNES

Direction Générale
Télécommunications, Industries de l'Information et Innovation

EXPOLANGUES '87, Paris

Exemple de traduction automatique Systran

TEXTE ORIGINAL

It will be particularly important to ensure the consistency of policy in the field of database services with that in other related areas, for example to:

- ensure that the potential economic, social and regional impact are fully taken into account in information market intiatives;

- reinforce the research and development and use of automatic translation facilities;

TRADUCTION BRUTE SYSTRAN

Sarà in particolare importante assicurare la consistenza di politica nel campo di servizi della base di dati con quello in altri settori riferiti, per esempio a:

- assicurarsi che l'effetto economico, sociale e regionale potenziale interamente sia considerato in intiatives del mercato dell'informazione;

- rinforzare la ricerca e lo sviluppo e l'impiego di agevolazioni della traduzione automatica;

- encourage the implementation of international standards in the field of information services.

5.2.2. Policy development process

5.2.2.1. Senior Officials Advisory Group (SOAG)

Some urgent policy objectives have been identified in this document. However, the policy development process in an ongoing one requiring a great deal of consultation, analysis and consensus-forming among the Member States. It is proposed that the focal point for this policy development and review process is the Senior Officials Advisory Group (SOAG) for information market policy. SOAG's responsibilities include the following:

- to advise the Commission on information market policy goals and priorities;

- to help the Commission examine problem areas and issues within the information market policy framework;

- to aid the formulation of convergent information market policies at national and Community level, avoiding unnecessary duplication of effort.

As legal aspects are an area requiring particularly urgent attention at the present time, it is proposed that the findings of the Legal Observatory expert group currently advising the Commission are submitted also to SOAG as part of the input for policy formulation.

- incoraggiare l'esecuzione di norme internazionali nel campo di servizi d'informazione.

5.2.2. Processo di sviluppo politico

5.2.2.1. Gruppo consultivo dei funzionari (SOAG)

Alcuni obiettivi urgenti della politica sono identificati in questo documento. Tuttavia, il processo di sviluppo politico un in corso che richiede molta consultazione, analisi e che si forma consenso fra gli stati membri. Si propone che il punto focale per questo processo di sviluppo politico e di esame sia il gruppo consultivo dei funzionari (SOAG) per la politica del mercato dell'informazione. Le responsabilità del SOAG includono cio' che segue:

- consigliare la Commissione su scopi e su priorità della politica del mercato dell'informazione;

- aiutare la Commissione ad esaminare settori problematici e questioni nel quadro della politica del mercato dell'informazione;

- aiutare la formulazione di politiche convergenti del mercato dell'informazione a livello comunitario e nazionale, prevenzione di doppione superfluo di sforzo.

Poichè gli aspetti legali sono un settore che richiede in particolare l'attenzione urgente attualmente, si propone che i risultati del gruppo di esperti dell'osservatorio legale attualmente che consiglia la Commissione siano presentati inoltre a SOAG come componente dell'input per la formulazione della politica.

COMMISSION
DES COMMUNAUTÉS
EUROPÉENNES

Direction Générale
Télécommunications, Industries de l'Information et Innovation

EXPOLANGUES '87, Paris

Exemple de traduction automatique Systran

TEXTE ORIGINAL

1. INTRODUCTION

1.1. Généralités

FSSRS (Farm Structure Survey Retrieval System) est un logiciel qui permet: la consultation, l'extraction et la manipulation des données des enquêtes sur la structure des exploitations agricoles.

Ce logiciel, suite à une demande de la division E4 "Comptes et Structures Agricoles" de l'OSCE, a été conçu par Monsieur Guido Vervaet de l'unité A1 de l'OSCE et réalisé par Messieurs Neal Garlick et Steve Ditchburn de la société "ARONWORTH".

FSSRS est opérationnel depuis le début de 1984 et tourne actuellement sur un ICL 39/80.

La gestion de la base et l'aide aux utilisateurs sont assurées par M. LENTSCHAT Jean Marie (OSCE-E4, JMO B3/010, BAT. JEAN MONNET, LUXEMBOURG, Tél. 4301-2064).

L'utilisation de FSSRS est basée sur un système de menus hiérarchisés d'un usage assez aisé. L'utilisateur a la possibilité de travailler en Français, Anglais ou Allemand. Ce manuel de consultation et le manuel "Contenu de la base" ne sont disponibles qu'en Français et en Anglais; cependant si la demande existe ils pourraient être traduits en Allemand.

TRADUCTION BRUTE SYSTRAN

1. INTRODUCTION

1.1. General information

FSSRS (Farm Structure Survey Retrieval System) is a software which allows: the consultation, the retrieval and the manipulation of the data investigations about the structure of the farms.

This software, further to a request of the division E4 "agricultural accounts and structures" of the SOEC, was conceived by Mr Guido Vervaet of the unit A1 of the SOEC and carried out by Messrs Neal Garlick and Steve Ditchburn of "ARONWORTH" company.

FSSRS is operational since the beginning of 1984 and turns currently on ICL 39/80.

The management of the base and the aid for users is ensured by Mr LENTSCHAT Jean Marie (OSCE-E4, JMO B3/010, BAT. JEAN MONNET, LUXEMBOURG, tel. 4301-2064).

The use of FSSRS is based on a system of hierarchised fragments rather easy use. The user has the possibility of working as Frenchmen, Englishmen or German. This consultation handbook and the handbook "contents of the base" is available only as Frenchmen and as Englishmen; meanwhile if the request exists they could be translated into a German.

Documentation

Le présent manuel contient uniquement les explications sur les facilités d'utilisation de FSSRS. Pour savoir quelles sont les données contenues dans FSSRS l'utilisateur doit se reporter au manuel "FSSRS contenu de la Base", et pour une bonne interprétation de ces données il est indispensable de se référer aux publications suivantes:

Pour l'enquête structure agricole 1975:

- Enquête Communautaire sur la structure des exploitations agricoles 1975 Volume I "Introduction et bases méthodologiques" (Luxembourg 1978)

Pour l'enquête structure agricole 1977:

- Introduction: Doc. D/SB/317 (disponible sur demande auprès de l'EUROSTAT, division E4)

Pour l'enquête structure agricole 1979/80:

- Enquête communautaire sur la structure des exploitations agricoles 1979/80 Volume I "Introduction et bases méthodologiques"

Pour l'enquête structure agricole 1983:

- Enquêtes communautaires sur la structure des exploitations agricoles Volume I "Introduction et bases methodologiques"

N.B.: Ce volume sera également valable pour les enquêtes de 1985 et 1987.

Documentation

This handbook only contains the explanations on the uses of FSSRS. to know what are the data contained in FSSRS the user has to refer to the handbook "contained FSSRS of the base", and for a good an interpretatation of these data it is essential to refer to the following publications:

For the farm structure survey 1975:

- Community survey on the structure of agricultural holdings 1975 volume I "introduction and methodological bases" (Luxembourg 1978)

For the farm structure survey 1977:

- Introduction: Doc. D/SB/317 (available on request to EUROSTAT, division E4)

For the farm structure survey 1979/80:

- Community survey on the structure of agricultural holdings 1979/80 volume I "introduction and methodological bases"

For the farm structure survey 1983:

- Community surveys on the structure of agricultural holdings Volume I "methodologiques introduction and bases"

N.B.: this volume will be also valid for the surveys of 1985 and 1987.

1.3. Autorisation et sécurité d'accès

Les données contenues dans FSSRS sont publiques, mais le logiciel ne permettant actuellement que l'accès à la base via des terminaux "mode page" connectés au site central, seuls les utilisateurs internes aux institutions européennes ont la possibilité de consulter la base.

1.3. Access authorization and security

The data contained in FSSRS are public, but software the not allowing currently that access to the base via terminals "page mode" connected to the central site, only the users within the European institutions has the possibility of consulting the base.

b) Programme de la Présidence luxembourgeoise

Le 10 juillet 1985, M. Jacques POOS, ministre des affaires étrangères luxembourgeois et Président en exercice du Conseil, a présenté devant l'Assemblée plénière le programme de la Présidence luxembourgeoise. En évoquant les principaux axes sur lesquels devrait se développer l'action du Conseil au cours du semestre de la Présidence luxembourgeoise, il a indiqué que la véritable priorité restait la lutte contre le chômage, notamment par un redressement de l'économie communautaire garantissant une croissance plus dynamique et créatrice d'emplois. A ce titre, il a particulièrement mis l'accent sur la nécessité d'aller de l'avant dans la réalisation d'un marché unique, la convergence des politiques économiques et la coopération technologique.
Quant à la consolidation de l'acquis communautaire, il a énuméré les dossiers que la Présidence se proposait de faire progresser, à savoir ceux afférents aux politiques sociales, sidérurgique, énergétiques, des transports, de protection de l'environnement et des consommateurs, ainsi que la poursuite de la réflexion sur la politique agricole commune.

b) Programme of the Luxembourg presidency

10 July 1985, Mr Jacques POOS, Luxembourg Foreign Minister and President-in-Office of the Council, presented before the plenary assembly the programme of the Luxembourg presidency.
By evoking the principal axes on which should develop the action of the Council during the six-month period of the Luxembourg presidency, it showed that the genuine priority remained the fight against unemployment, in particular by a recovery of the Community economy guaranteeing more dynamic and creative growth of jobs. In this connection, it particularly laid the stress on the need to go of before in the realization of a single market, the convergence of the economic policies and technological cooperation.

As for the consolidation of the 'acquis communautaire', it listed the files that the presidency proposed making progress, namely that related to policies the social, iron and steel, energy, of transport, of protection of the environment and of the consumers, as well as the continuation of the reflexion on the Common Agricultural Policy.

COMMISSION
DES COMMUNAUTÉS
EUROPÉENNES

Direction Générale
Télécommunications, Industries de l'Information et Innovation

EXPOLANGUES '87, Paris

Exemple de traduction automatique Systran

TEXTE ORIGINAL

In the discussions the proposal has been watered down, removing the principle of free passage and largely excluding Greece, Ireland and the United Kingdom from the effects of the directive. This is achieved by distinguishing between land borders - where spot checks are duly "introduced" (for the greater part in confirmation of existing bilateral or multilateral agreements) - and ports and airports where Member States are merely exhorted to take all possible steps to ease controls.

TRADUCTION BRUTE SYSTRAN

In den Verhandlungen ist der Vorschlag, das Prinzip freier Durchfahrt und mit Ausnahme Griechenlands, Irlands und des Vereinigten Königreichs von den Auswirkungen der Richtlinie grosstenteils entfernend verwässert worden. Wird dieses durch Unterscheidung zwischen Grenzen des Landes - wo Stichproben ordnungsgemäss "eingeführt werden erreicht" (für den grösseren Teil in Bestätigung existierender bilateraler oder multilateraler Uebereinstimmungen) - und Häfen und Flughäfen, wo die Mitgliedstaaten bloss ermuntert werden um alle möglichen Schritte zu unternehmen um Kontrollen zu erleichtern.

b) The first obstacle to adoption of the directive is the Danish insistence on retention of the benefits of the passport agreement under which it is possible to move between the Nordic states without a passport. The Nordic states guarantee to each other effective controls at their external borders (in the case of Denmark the Danish-German border) so that the passport agreement is incompatible with the draft directive which would require easing of checks at the Danish-German border. The Internal Market Council of 23rd June 1986 invited the Commission to hold exploratory talks to see whether the Nordic states would be interested in negotiating an agreement with the Community on the easing of border checks. Lord Cockfield reported to the Internal Market Council of 1st December 1986 on the talks and suggested that the Commission continue to seek the conditions under which reciprocal benefits could be extended.

b) Das erste Hindernis für Annahme der Richtlinie ist das dänische Beharren auf Beibehaltung der Vorteile der Passübereinstimmung, unter der es möglich ist zwischen die nordischen Staaten ohne einen Pass sich zu bewegen. Die nordischen Staaten garantieren miteinander wirksame Kontrollen an ihren äusseren Grenzen (im Falle Dänemarks die dänisch-deutsche Grenze), so dass die Passübereinstimmung inkompatibel mit dem Richtlinienentwurf ist der Erleichterung von Kontrollen an der dänisch-deutschen Grenze erfordern würde. Der Rat für Fragen des Binnenmarktes vom 23. Juni 1986 forderte die Kommission auf, informatorische Besprechungen zu halten, zu sehen, ob die nordischen Staaten an Verhandlung eines Abkommens mit der Gemeinschaft auf der Erleichterung von Grenzkontrollen interessiert würden. Lord Cockfield berichtete dem Rat für Fragen des Binnenmarktes vom 1. Dezember 1986 auf den Besprechungen und schlug vor, dass die Kommission fortfährt die Bedingungen zu suchen unter denen gegenseitige Vorteile ausgedehnt.

He called on the Council to adopt the proposal with a temporary derogation for Denmark covering the period of talks.

Nach der Diskussion identifizierte der Vorsitzende wie folgt in das Protokoll aufgenommene Erklärungen des Kompromisses:

After discussion the President identified compromise minutes declarations as follows:
Delegations did not comment on these declarations, which will be submitted to the Council, except that the Commission and Netherlands representatives had technical reserves on the 18 month definition of old butter, and the Netherlands representative resisted the restriction of the operations to those stated in the explanatory memorandum.

Die Delegationen nahmen nicht zu diesen Erklärungen Stellung, die dem Rat unterbreitet werden werden, ausser dass hatten die Kommission und die Vertreter der Niederlande technische Vorbehalte betreffend der 18-monatigen Definition alter Butter, und der Vertreter der Niederlande widersetzte sich der Beschränkung der Operationen zu jenen die im erläuternden Memorandum erklärt wurden.

e) The Irish representative complained that the provisions on interest rates were unfair to countries with high domestic rates, but said that this should not prevent agreement on the regulation. Mr O'Leary considered there was an element of double funding as the sales of concentrated butter were already funded under the co-responsibility levy. He noted the statement of the Commission representative that the estimated disposal costs included any export refunds which would be payable.

e) Der irische Vertreter beklagte, dass die Bestimmungen zu Zinssätzen unfair zu den Ländern mit hohen einheimischen Quoten waren, aber sagte dass dieses keine Uebereinstimmung zur Verordnung verhindern sollte. Herr O'Leary erwog, es gäbe ein Element doppelter Finanzierung da die Verkäufe konzentrierter Butter schon unter der Mitverantwortungsabgabe finanziert wurden. Er nahm die Erklärung des Kommissionsvertreters zur Kenntnis, dem die geschätzten Beseitigungskosten alle Ausfuhrerstattungen einbezogen die zahlbar sein würden.

l' analyse de l' essai CABRI B1 était difficile en raison des effets bidimensionnels du mouvement et de la perturbation apportée par la cage de centrage. Le code a retrouvé l' instant et l' endroit où s' amorce le mouvement et le fait que celui-ci est d' abord ascendant. La propagation du front de fusion et la hauteur de la zone fondue ont été calculées à 7 % près. De plus comme dans l' expérience on constate que la relocalisation se fait à l' intérieur de la zone fondue, c' est-à-dire dans la partie fissile (faible pénétration de l' acier liquide sur la gaine intacte) et que les centreurs constituent une zone de resolidification préférentielle. Par contre le calcul n' a pas retrouvé la fusion des centreurs qui a pourtant été observée. Par ailleurs on peut vérifier sur la figure 32 que si l' emplacement de certains bouchons est correct, d' autres n' ont pas été retrouvés; mais ceci est lié à des particularités de l' expérience qui ne se retrouveront pas en réacteur. On peut donc considérer que ces essais ont permis de qualifier le code ALFA; des essais complémentaires permettront de préciser l' effet des centreurs (essais MONOBRI) et de l' irradiation (essais CABRI). Par ailleurs ils ont permis d' établir plusieurs points dont nous verrons l' importance pour l' application au réacteur:

397 The analysis of the CABRI test B1 was difficult owing to the two-dimensional effects of the movement and of the perturbation brought by the cage of centering. The code
398 found the moment and the place when starts the movement and the fact that this one is initially ascending. The
399 propagation of the front of fusion and the height of the melted zone were calculated with a margin of 7 %. Moreover
400 as in the experience it is noted that the relocalisation is done inside the melted zone, i.e. in the fissile part (small penetration of molten steel on the intact clad) and that the centring devices constitute a preferential resolidification zone. On the other hand calculation did not find the fusion
401 of the centring devices who however was observed. In
402 addition one can check on figure 32 only if the site of some plugs is correct, others were not found; but this is
403 connected with characteristics of the experience who will not be found in reactor. One thus can consider that these
404 tests allowed to qualify the ALFA code; complementary tests
405 will make it possible to specify the effect of the centring devices (MONOBRI tests) and of the irradiation (CABRI tests). In addition they allowed to draw up several points
406 of which we will see the importance for the application to the reactor:

La qualité des traductions peut être évaluée à partir des indications suivantes :

SYSTRAN 3.7 : QUALITE DE TRADUCTION

couple de langues	date	total des mots	pourcent. d'erreurs	qualité générale de la traduction	TAILLE DES DICTIONNAIRES DE SYSTRAN	
					total des entrées	total des significations
anglais espagnol	25/2/88	6.545	12.3	87.7	154.135	44.912
anglais français	25/2/88	6.545	11.1	88.9	154.135	154.538
anglais italien	25/2/88	6.545	29.0	71.0	154.135	142.397
anglais russe	01/06/87	6.545	32.8	67.2	19.329	34.773
anglais portug.	01/06/87	6.545	29.6	70.4	154.135	31.918
anglais allemand	25/2/88	6.545	29.8	70.2	154.135	124.245
anglais japonais	25/2/88	6.517	30.3	69.7	154.135	66.481
allemand espagnol	01/06/87	5.405	40.4	59.6	126.617	47.902
allemand français	01/06/87	5.405	67.6	32.4	126.727	28.610
allemand italien	01/06/87	5.405	80.2	19.0	125.426	17.736
français allemand	01/06/87			expérim.	62.994	47.398
russe anglais	01/06/87	8.654	4.6	95.4	346.018	487.585
français anglais	01/06/87	8.344	13.7	86.3	117.401	136.367
allemand anglais	01/06/87	5.405	20.9	79.1	129.768	159.258
japonais anglais	01/06/87	9.140	33.0	67.0	45.394	56.523
espagnol anglais	01/06/87	9.017	23.0	77.0	32.669	36.439
italien anglais	01/06/87			expérim.		
portugais anglais	01/06/87			expérim.		

.SYSTRAN 3.7 : QUALITE DE TRADUCTION (suite)

couple de langues	CATEGORIE D'ERREUR et POURCENTAGE D'ERREURS PAR CATEGORIE						
	problèmes de sens	mots non trouvés	POS incorr. (homograph)	forme incorrecte	relations syntaxiques	ordre des mots	autres
anglais espagnol	28.0	26.9	11.8	21.1	1.5	9.9	0.8
anglais français	28.6	20.2	11.7	7.0	13.9	6.0	12.6
anglais italien	41.0	18.5	12.9	7.0	14.5	2.8	3.4
anglais russe	12.2	23.2	12.7	41.3	5.5	1.0	4.1
anglais portug.	40.3	21.6	6.5	22.3	8.7	0.1	0.5
anglais allemand	31.2	21.5	11.9	10.3	3.5	8.1	13.5
anglais japonais	32.9	11.2	20.1	3.7	18.4		13.7
allemand espagnol	37.9	55.7	0.3	4.8	4.3	1.3	1.5
allemand français	9.9	75.3	1.2	4.1	0.4	3.7	0.3
allemand italien	1.0	95.1	0.3	2.2	14.0	0.7	12.5
français allemand							
russe anglais	26.0	0.5	2.5	3.3	27.3	17.3	23.1
français anglais	47.6	6.2	15.0	8.0		6.5	
allemand anglais	31.3	25.7	6.5	4.3	4.7	5.7	12.0
japonais anglais	36.4	4.6	1.4	6.4	18.4	14.0	17.3
espagnol anglais	41.0	18.0	17.0	14.0	6.0	2.5	1.5
italien anglais							
portugais anglais							

TESTS DE QUALITE DE SYSTRAN

N°		% de qualité
1	russe-anglais	95.4
2	anglais-français	88.9
3	anglais-espagnol	87.7
4	français-anglais	86.3
5	anglais-arabe	83.0
6	allemand-anglais	79.1
7	espagnol-anglais	77.0
8	anglais-italien	71.0
9	anglais-portugais	70.4
10	anglais-allemand	70.2
11	anglais-russe	67.2
12	japonais-anglais	67.0
13	allemand-français	*
14	allemand-italien	*
15	anglais-néerlandais	*
16	français-néerlandais	*
17	français-allemand	*
18	français-italien	*

Ces critères ont été établis par la Sté LATSEC pour le service réception de ses clients.

SYSTRAN fonctionne sur un IBM 360/50. Un système opérationnel doit être disponible sur l'ordinateur AMDHAL de la Commission, (sous MVS). Une adaptation du logiciel à l'environnement UNIX est à l'étude. Ce système à transfert, basé sur une approche directe est complètement automatisé.
Les performances annoncées sont de 2 millions de mots/ heure de temps calcul. On prévoyait une production de 300 000 pages/an. Or SYSTRAN n'a traduit que 2800 pages en 1987 pour la CEE (Si l'on se livre à un rapide calcul, en comptant 250 mots pour une page type (standard européen), 2800 pages représentent 700 000 mots. Conclusion : SYSTRAN a fonctionné moins de 20 minutes - temps calcul - en 1987, pour traduire les textes de la CEE !).
Sa conception modulaire facilite son extension à d'autres couples de langues. Aux Communautés Européennes, il fonctionne sur 12 couples.

Extraits de la documentation **SYSTRAN** 1990 :

LA QUALITE SYSTRAN

LANGUE SOURCE	LANGUE CIBLE	QUALITE en%
ANGLAIS	Français	89
	Arabe	86
	Espagnol	75
	Italien	72
	Néerlandais	71
	Portugais	70
	Allemand	70
	Russe	65
FRANÇAIS	Anglais	86
	Italien	80
	Néerlandais	75
	Allemand	70
RUSSE	Anglais	96
ALLEMAND	Anglais	80
	Français	70

EXEMPLE CHIFFRE

CONDITIONS	NOMBRE DE PAGE/HEURE (moyenne)	EXEMPLE : 1 000 PAGES EN HEURES	COUT	
TRADUCTION HUMAINE	1	1 000 H (18 semaines)		250 000
TRADUCTION PAR SYSTRAN	2 000	0H 30	75 000	
REVISION	3	330 heures (6 semaines)	82 500	
		TOTAL	157 500	250 000

BILAN PAR SYSTRAN POUR 1 000 PAGES :

- ECONOMIE : 92 500 F
- TEMPS GAGNE : 12 SEMAINES

3.3.3.2.10 SYSTRAN Japon

Les systèmes anglais-japonais et japonais-anglais ont été développés par la société IONA (responsable du développement et de l'exploitation de SYSTRAN au Japon). Ils sont utilisés par de grandes oragnisations. La société dispose d'un bureau de traduction à Tokyo qui produit plus de 10 000 pages /an. Les deux logiciels fonctionnent sur un FACOM M-380, à une vitesse de 2 millions de mots/heure de temps calcul.

Exemples de traduction :

シストラン世界大会に出席するために、世界各地から
シストランに興味を持つ人々がルクセンブルグに集まった。

IN ORDER TO ATTEND THE WORLD SYSTRAN CONFERENCE,
PEOPLE WHO ARE INTERESTED IN SYSTRAN GATHERED IN
LUXEMBOURG FROM DIFFERENT PARTS OF THE WORLD.

本
(HON)
↓
A BOOK, BOOKS, THE BOOK, THE BOOKS

沢山の本
(TAKUSAN NO HON)
↓
MANY BOOKS

PEOPLE INTERESTED IN SYSTRAN GATHERED HERE TODAY FROM ALL OVER THE WORLD

1 2 3 4 5 6 7 8 9 10 11 12

↓

世界中から今日ここにシストランに興味を持つ人々が集まった。

SEKAI JU KARA KYO KOKONI SISUTORAN NI KYOMI WO MOTU HITOBITO GA ATUMATTA

12 9 8 7 6 4 3 2 1 5

I WILL TAKE MY SISTER WITH ME.

↓

連れていく。

(TSURETEIKU)

I WILL TAKE MY CAMERA WITH ME.

↓

持っていく。

(MOTTEIKU)

3.3.3.2.11 TAURAS[1]

Lancé sur le marché en 1987 par la société TOSHIBA (Japon), TAURAS (Toshiba Automatic Translation System Reenforced by Semantics) est un système multilingual qui fonctionne pour l'instant sur le couple anglais-japonais et très bientôt sur le couple japonais-anglais.

---

(1) S. MELI : "Informationsmarkt der maschinellen Übersetzung" in *Terminologie et Traduction*, Commission des Communautés Européennes, n°3, 1989, pp. 83-84

L'analyse syntaxique est basée sur une grammaire d'ATNs, (réseaux de transition augmentés, paragraphe 2.7.4.3). L'analyse sémantique repose sur des règles sémantiques associées à des règles lexicales dans le dictionnaire, au niveau duquel syntaxe et sémantique fonctionnent de façon complémentaire : si le traitement sémantique échoue, on soumet à nouveau la phrase à l'analyse syntaxique.
Le logiciel fonctionne sur un MC 68020 sous le système d'exploitation UNIX. Il est écrit en language C. C'est un système de transfert qui traduit les textes techniques ou scientifiques, de l'anglais vers le japonais et dispose d'un dictionnaire de 50 000 entrées, 50 000 termes techniques auxquels il faut ajouter les 30 000 termes du dictionnaire de l'utilisateur. Il traduit à une vitesse de 7 000 mots/heure.

3.3.3.2.12 WEIDNER[1,2]

La Weidner Communications Corporation créée en 1977 par Bruce WEIDNER a développé avec des chercheurs qui avaient travaillé sur le projet BYU (paragraphe 3.3.2.5) le système anglais-français pour le MITEL (Canada) et le système anglais-espagnol pour SIEMENS (Etats-Unis).
En 1981 le MITEL utilise le couple anglais-espagnol et anglais-allemand,BRAVICE[4] (bureau de traduction à Tokyo) acquiert le système anglais-espagnol, espagnol-anglais. En 1989, 25 systèmes WEIDNER sont installés dans le monde. Le processus de traduction (méthode directe) est totalement automatisé, peu évolué (analyse locale), mais le système est vendu comme un système d'aide à la traduction qui fonctionne en mode interactif (pré-analyse lexicale, construction de dictionnaires...) et intègre un traitement de texte avec des interfaces variées. Une des caractéristiques du logiciel est d'accepter un texte dans n'importe quel format et de le conserver pour l'impression de la sortie. Contrairement aux autres systèmes de T.A.O., il ne nécessite pas de pré-édition.

On distingue quatre étapes dans la traduction, indépendantes les unes des autres.
- Pré-analyse : Repérage des phrases, insertion des marqueurs de mise en forme, identification des commandes de composition, analyse morphologique des mots du texte source (suppression des inflexions, repérage des racines), désambiguïsation des homographes.
- Isolement des groupes de mots qui fonctionnent comme une même entité linguistique (compactage), recherche des syntagmes verbaux... Ces groupes sont considérés comme des éléments uniques et on leur associe des informations syntaxiques et sémantiques pour une analyse ultérieure.
- Analyse syntaxique, effectuée de gauche à droite. Les informations relatives à la structure de la phrase sont conservées pour une réorganisation ultérieure dans la structure de la langue cible.
- Transfert : la structure de la langue source est transformée en structure de la langue cible. Un programme d'insertion insère le texte selon la structure de la langue cible, les articles, les prépositions. Les mots et expressions sont remis à leur place et le texte mis en forme. Le programme d'extension transforme les expressions compactées en les plaçant dans la structure de la langue cible.
- La synthèse restitue les marques de déclinaison et ajuste l'orthographe.
- Le post-traitement rétablit la mise en page et les formats et traite les mots qui n'ont pas été traduits. La traduction est stockée dans un fichier de sortie.

---

(1) **Secretary of State of Canada** : Essai de traduction assistée par ordinateur : système WEIDNER Approvisionnements et Services Canada, Project 5-5462, 1985
(2) **M.G. HUNDT** : "Working with the Weidner Machine-Aided Translation System", in V. LAWSON (Ed.), 1982, *Practical Experience of Machine Translation*, Conference in London, novembre 1981, pp. 45-51, Amsterdam, North-Holland
(3) **TAKEHIKO YAMAMOTO** : "Le pari du dictionnaire universel" in *Dynasteurs*, novembre 1987

- L'édition conduit à la traduction définitive. Le système met à la disposition du traducteur un ensemble de fonctions de révision : l'AMENDER (fonctions de traitement de texte, affichage des textes source et cible sur écran partagé, ajout ou suppression de mots ou expressions, dictionnaire des synonymes).
On constate que l'ordre dans lequel interviennent les étapes n'est pas compatible avec une traduction de qualité, seule la possibilité de traduire 800 mots à l'heure justifiant l'utilisation du système. Un affichage des menus assure la convivialité du système. Une option "recherche du vocabulaire" améliore la traduction. Le programme recherche les mots du texte qu'il ne comprend pas pour les proposer à l'utilisateur sous plusieurs formes (liste alphabétique, liste par fréquence d'apparition, liste avec contexte). Un module de mise à jour du dictionnaire permet à l'utilisateur de personnaliser le système.
Après avoir développé les couples anglais-allemand et allemand-anglais pour ITT (Grande-Bretagne) en 1982, WEIDNER a travaillé avec la compagnie BRAVICE (Japon) pour la mise au point des couples japonais-anglais, anglais-japonais.
Les programmes écrits en FORTRAN ont été implantés sur microordinateur (IBM PC...) pour s'affranchir des gros calculateurs. Les produits ont alors été commercialisés par la société TAO International sous le nom de MICROCAT (IBM XT et compatibles) et MACROCAT (PDP 11 ou VAX, Microvax II de DEC). Ces produits semblent avoir disparu du marché nord-américain et européen. Seule la société BRAVICE continue de l'exploiter au Japon.

MicroCat

At last... foreign language translation-on a personal computer!

Now computer-aided translation is practical and affordable for organizations or individuals with moderate translation demand.

The MicroCat from TAO International is a personal computer-based foreign language translation system. It is designed for use by one translator working in one language direction, such as English to Spanish. In addition, when the MicroCat is not in use for its translation application, it can be used for word processing, financial spread sheets, and other personal computer programs.

Protect your information.

For those who must translate proprietary text, the Microcat system guarantees complete internal security. You control sensitive information at all times.

MicroCat is IBM compatiable.

The MicroCat system runs on an enhanced IBM XT Personal Computer and will accept all compatible software.

Speed, Productivity, and Savings.

The MicroCat can translate at speeds of up to 3000 or more words per hour. Rapid rough translations are highly accurate and relieve the translator of a major, tedious task. Since translators spend their valuable time editing and polishing the text stylistically, their productivity goes up and your costs go down.

Expandable Word Bank Improves Technical Translations.

For each language direction, a core dictionary of about 9000 words is built into the MicroCat system. In addition, a Dictionary Update function allows you to add or delete words or phrases in seconds. With this powerful MicroCat feature, you can add to the system dictionary words and idioms unique to your international communications. Technical documents such as training manuals, scientific reports, and parts lists are handled more easily than ever before.

On-screen editing with Multilingual Word Processor

The translator's job is made even easier because the MicroCat system displays on a split screen both the source and target languages. And its built-in multilingual word processing capability, with an international character set, provides powerful text manipulation capability, including Word Swap, Phrase Movement, and all other standard word processing functions.

MicroCat specifications.

Language Directions:
(Available or being developed).

English to French,
French to English,
English to Spanish,
Spanish to English,
English to German,
German to English,
English to Portuguese.

Hardware:

Enhanced IBM XT Personal Computer,
640 KB Memory,
10 MB Disk Drive,
NEC 3550 Letter Quality Printer
International Character Set
Key Template.

Foreign language translation: in the international marketplace, how well you do it can determine how well you do. TAO International Can Help You Do It Better.

MacroCat

The best computer-aided translation system on the market today.

For organizations with a heavy demand for foreign language translations. The MacroCat system from TAO International provides speed, accuracy, and a major reduction in expense.

The MacroCat system is a multi-user, multi-language translation system. It is designed for use by multiple translators working in one or more language directions simultaneously. This MacroCat system handles all major European language. Other language directions are currently in development.

Eight thousand words per hour.

There is no faster translation system. The MacroCat produces highly accurate rough translations at speeds of up to 8000 words per hour. For high volume users, the MacroCat is the key to translations that are fast, accurate, consistent, and economical. Because the MacroCat system produces high speed rough translations, your translators are spared that tedious and time consuming task. They spend their valuable time editing and polishing stylistically, producing precise final text. Productivity goes up. Costs go down.

No text is too difficult.

The MacroCat, with its Dedicated Word Bank, can translate even the most technical literature and it can handle great volume with relative ease. The more comprehensive your customized dictionary, the faster and more accurate are the rough translations. Technical documents such as training manuals, scientific reports, and parts lists are handled more easily than ever before.

Protect your information.

For those who must translate proprietary texts, the Macrocat system guarantees complete internal security. You control sensitive information at all times.

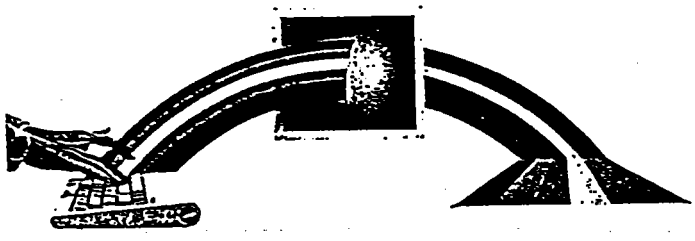

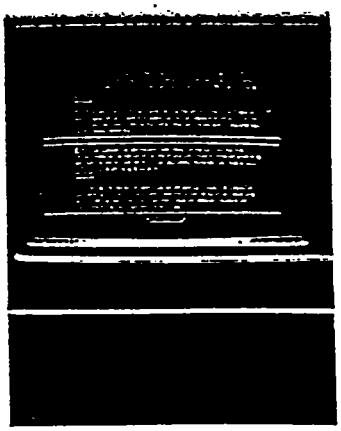

On-screen editing with Multilingual Word Processor

The translator's job is made even easier because the MacroCat system displays on a split screen both the source and target languages. And its built-in multilingual word processing capability, with an international character set, provides powerful text manipulation capability, including Word Swap, Phrase Movement, and all other standard word processing functions.

Foreign language translation: in the international marketplace, how well you do it can determine how well you do. TAO International Can Help You Do It Better.

Your Dedicated Word Bank.

For each language direction, the MacroCat system includes a core dictionary of about 9000 most commonly used words and phrases. In addition, will help you build, or build for you, a totally customized dictionary of words and phrases common to your organization or industry. Since adding a new word or idiom takes only seconds, your word base is easily and continuously expandable. This customized dictionary—your Dedicated Word Bank—is an exclusive feature of the CAT system. It is the key to consistent translations of even the most difficult text.

MacroCat specifications.

Language Directions:

(Available or being developed).

English to French,
French to English,
English to Spanish,
Spanish to English,
English to German,
German to English,
English to Portuguese.

Hardware:

PDP or VAX series from DEC.

To contact: TAO International
Call: (61) 22.87.77 — Telex: 520.379

2.3.3.3 Les systèmes dédiés

Ces systèmes ne sont pas commercialisés. Ils ont été conçus pour des applications précises et sont exploités en général par leurs concepteurs.

2.3.3.3.1 AMPAR[1]

Ce système de traduction "directe" est bilingue (anglais-russe). Développé à Moscou (All-Union Centre for Translation of Scientific and Technical Literature and Documentation", il fonctionne depuis 1979. Conçu à l'origine pour la traduction de texte politique, le centre l'utilise dorénavant pour traiter les domaines de l'informatique et de la programmation. Il peut être adapté à d'autres types de littérature scientifique et technique. Tout comme NERPA (paragraphe 2.3.3.3.5), il est présenté comme "multifonctionnel", c'est à dire qu'il peut être adapté à des documents de thèmes divers, de forme variable en entrée et propose une édition interactive, ce qui facilite la recherche dans les dictionnaires et autorise une correction et une actualisation rapides.

2.3.3.3.2 CHIMKENT[1]

Développé au CHIMKENT Pedagogical Institute for the Kazakh Academy of Sciences, le système traduit des textes sur la chimie et les polymères de l'anglais vers le russe. Il ne s'agit en fait que d'une traduction mot à mot.

2.3.3.3.3 CULT (Chinese University Language Translator)[2]

Utilisé pour assurer la traduction chinois-anglais des Acta Mathematica Sinica (1975) et des Acta Physica Sinica (1976), CULT est un des systèmes de Traduction Assistée par Ordinateur les plus intéressants. Il a été développé par l'université chinoise de Hong Kong à partir de 1968. Après avoir fonctionné sur un texte introduit sous forme de cartes perforées, le système a été réactualisé en 1978, avec l'ajout d'un module de traitement de texte.
La préédition est une étape très importante pour ce système à approche directe qui ne fonctionne que sur les textes cités plus haut et pour le couple chinois-anglais. La postédition se limite à la réintroduction de formules et de figures dans le texte de sortie. L'intervention du traducteur est requise en cours de traitement, pour la conjugaison des verbes et la déclinaison des noms.

2.3.3.3.4 FRAP[1]

Développé dans le même centre que le système AMPAR, il est en exploitation depuis 1981. Système à transfert, il traite des textes d'électronique, d'informatique, de navigation aérienne et de construction aéronautique, du français vers le russe.

2.3.3.3.5 NERPA[1]

Développé par le même centre, ce système repose sur les mêmes principes linguistiques qu'AMPAR et fonctionne sur le même environnement informatique. Il traduit de l'allemand vers le russe des textes d'informatique et de programmation.

---

(1) S. MELI : "Informationsmarkt der maschinellen Übersetzung" in *Terminologie et Traduction*, Commission des Communautés Européennes, n°3, 1989, pp. 83-84

(2) S.-C. LOH, L. KONG : "Automatische Übersetzung chinesischer wissenschaftlicher Zeitschriften", *Dritter Europäischer Kongress über Dokumentationssysteme und Dokumentationsnetze*, luxembourg, 3/6 mai 1977, vol. 1, pp. 563-578

2.3.3.3.6 SPANAM et ENGSPAN[1]

En 1975 la Pan American Health Organization (Washington D.C.) a entrepris le développement d'un système de traduction automatique pour les quatre langues officielles anglais, espagnol, français et portugais de l'organisation. Le système SPANAM traduit de l'espagnol vers l'anglais depuis 1980, ENGSPAN de l'anglais vers l'espagnol depuis 1984.

Les programmes (écrits en PL/1) fonctionnent sur calculateur IBM 4381, dans l'environnement DOS/VSE/SP. Une autre version est compatible avec l'IBM 3081 (OS/MVS). Les textes sont soumis et traités en sortie par une station dédiée au traitement de texte (WANG OIS/140), le traitement est automatique et ne fonctionne qu'en mode "batch". Il n'y a aucune restriction quant au domaine abordé par les textes à traduire et à la syntaxe utilisée, (la plupart du temps, médecine et santé). Des traducteurs entraînés au maniement des outils dont ils disposent, révisent les traductions à l'aide du traitement de texte. La production est de deux à trois fois plus importante que lors d'une révision manuelle (4000-10000 mots/jours pour la post-édition, 1500-3000 mots/jour pour une traduction manuelle).

La vitesse de SPANAM sur gros calculateur atteint 1500 mots/minute (495 000 mots/heure de temps CPU) et ses dictionnaires contiennent 61 282 entrées (langue source), 58 485 entrées (langue cible). Pour ENGSPAN, elle atteint 836 mots/minute (102 000 mots/heure de temps CPU), les dictionnaires contiennent respectivement 45 614 et 47 545 entrées. Les dictionnaires occupent chacun de 7 à 10 Mo.

Construits selon la même architecture modulaire, ils se différencient sur le plan de la linguistique, ENGSPAN, plus avancé, utilise les ATNs (paragraphe 1.5.4.3) et sépare les modules de transfert lexical et syntaxique. Le système SPANAM est amélioré au fil des découvertes et des progrès du système ENGSPAN.

Environnement

Dans les deux cas, il n'y a pas de *pré-édition* au sens linguistique du terme. Avec SPANAM, le document peut être saisi de façon automatique (Optical Character Recognition), ce qui nécessite alors une révision.

La *post-édition* est par contre indispensable. Confiée à des traducteurs-réviseurs entraînés (variété des applications oblige), elle peut être modulée selon plusieurs critères (destination de la traduction, délais impartis, structure linguistique du texte...) et permet de modifier rapidement les constructions fréquentes qui ne sont pas conformes, grâce à des outils appropriés comme les QFP ("Quick Fix" post-editing expedient) et des utilitaires de traitement de texte pour la recherche et la modification des chaînes de caractères. La philosophie retenue est d'introduire le minimum de correction pour obtenir une traduction acceptable. Réalisée à l'écran, elle est associée au traitement de texte qui automatise les opérations répétitives (fonctions SEARCH and REPLACE, SEARCH and DELETE...). Dans le but d'accélérer le fonctionnement du système, les tâches apparemment simples sont également optimisées. Le positionnement du curseur peut induire une perte de temps considérable de sorte qu'on lui préfère la fonction clavier SEARCH et l'utilisation d'une souris. Les techniques du traitement de texte et de la pré-édition sont mises à la disposition du traducteur pour l'actualisation des dictionnaires.

---

(1) M. VASCONCELLOS : "Management of the Machine Translation Environment : Interaction of functions at the Pan American Health Organization" in V. LAWSON, (ed.), *Practical Experience of Machine Translation*, North-Holland, Amsterdam, 1982, pp. 115-129

Comme pour SYSTRAN, les spécialistes du département des Langues ont la possibilité de trier les textes destinés à la traduction automatique ou manuelle. Une des particularités des systèmes ENGSPAN et SPANAM est leur intégration dans un service complet de traduction, dans le sens où ils peuvent être associés à des postes de travail compatibles et complémentaires. Ils aident alors la traduction humaine en apportant la puissance de leurs microglossaires spécialisés, inversement, des programmes de comptage de mots et des correcteurs orthographiques soulagent l'ordinateur central.

Fondements des systèmes

Le système SPANAM est au départ un système de traduction directe, avec analyse de la langue source (espagnol), transformation des structures de surface pour obtenir le cadre syntaxique propre à la langue cible (anglais), introduction des termes anglais selon les résultats de l'analyse, insertion et/ou suppression de certains morphèmes grammaticaux, synthèse des terminaisons pour l'anglais. Les principales étapes de la traduction sont : l'analyse morphologique, recherche des unitermes puis des multitermes dans le dictionnaire, résolution des homographes, identification du sujet, traitement des prépositions, des pronoms, des syntagmes verbaux, insertion du sujet, réorganisation des groupes nominaux, recherche du vocabulaire de la langue cible et synthèse.
L'analyse morphologique recherche les mots espagnols (formes radicales), reconnaît les morphèmes du pluriel et du féminin pour les noms, pronoms, déterminants, quantificateurs et adjectifs, détermine la personne et le temps des verbes, traite les composés et la capitale à l'initiale de la phrase. L'utilisateur a la possibilité d'entrer des mots dans le dictionnaire, sous leur forme complète (obligatoire pour les formes irrégulières et les homographes), fléchies ou radicales.
SPANAM traite les ambiguïtés à différents stades du traitement (recherche dans le dictionnaire, examen du contexte). Les différentes classes auxquelles peut appartenir le mot testé sont codées à la suite de l'entrée du dictionnaire, sous la forme d'un ensemble de bits.

Le système ENGSPAN est un système à transfert lexical et syntaxique, avec l'analyse séparée de l'anglais langue source, l'application de routines de transfert basées sur l'analyse contrastive de l'anglais et de l'espagnol, et la syntaxe de la langue cible l'espagnol. Les principales étapes sont : l'analyse morphologique, la recherche des unitermes, l'analyse au niveau de la phrase, le transfert lexical, la recherche des traductions dans le dictionnaire, la transfert syntaxique et la synthèse. Si l'analyse de la phrase échoue, des routines sont activées pour la résolution des homographes, l'analyse des groupes verbaux et des groupes nominaux. L'analyse morphologique (LEMMA) ne démarre que si la forme complète n'a pas été reconnue dans le dictionnaire. La procédure teste la présence de certaines terminaisons, les supprime pas à pas et compare avec le dictionnaire, en s'appuyant sur des règles morphologiques et orthographiques (ajout ou suppression du *e* final selon ce qui précède...), accompagnées d'une longue liste d'exceptions. Les mots non trouvés sont considérés comme des noms communs (noms propres s'ils commencent par une majuscule), verbes ou adjectifs potentiels. Les informations provenant de LEMMA et l'étude de la suffixation confirment ou infirment la nature du mot, suppriment ou ajoutent des possibilités d'ambiguïtés.
Dans ENGSPAN, la résolution des homographes a lieu au niveau de l'ATN. La fonction de chaque mot dépend du chemin emprunté dans le réseau. Pour aboutir à une analyse correcte, l'information lexicale fournie par le dictionnaire est utilisée de trois façons :
- les idiotismes ou les expressions multitermes sont stockées dans un enregistrement unique et n'appartiennent ainsi qu'à une classe.
- les unités analysées peuvent indiquer qu'un groupe de mots est associé à tel type de fonction.
- Un uniterme est associé à un code qui indique la probabilité pour qu'il appartienne à une classe donnée.

Traitement de la polysémie

SPANAM et ENGSPAN disposent de deux outils pour traiter la polysémie : les microglossaires et les unités de transfert.
Les **microglossaires** sont des sous-ensembles des dictionnaires (langue source-langue cible) que l'utilisateur peut appeler pour des applications particulières, (loi, agriculture, finance, informatique, ingénieurie médicale, recherches biomédicales), au moment de la traduction.
L'**unité de transfert** est une règle de transfert lexical stockée dans le dictionnaire source, qui spécifie une condition à tester (ce verbe a *n* objets) et une action à réaliser (choix d'une traduction, insertion d'une préposition, suppression d'un mot...).

Les caractéristiques syntaxiques et sémantiques

Elles sont codées sous forme binaire dans chaque enregistrement d'une entrée de dictionnaire et sont utilisées à toutes les étapes de la traduction. Dans ENGSPAN l'analyse produit un graphe de noeuds correspondant à chaque proposition, à chaque phrase. A chaque noeud correspond un tableau contenant les constituants, leur rôle et leur localisation (numéro du mot s'il s'agit d'une unité lexicale simple, pointeur du noeud approprié si c'est une proposition ou une phrase). Chaque noeud contient des règles applicables (type, mode, personne, nombre, temps, aspect, voix...).
Le formalisme des ATNs et la représentation structurale s'inspirent profondément de la théorie des réseaux de transition augmentés et de la grammaire systémique de WINOGRAD (1.4.3.5), reprenant des travaux de W.A. WOODS[1,2] et de R. M. KAPLAN[3]. La grammaire du système ENGSPAN est basée sur 11 réseaux (phrase, proposition, groupe nominal, groupe verbal, nominalisation, composés avec tiret, groupes prépositionnels, comparaison, groupe adverbial, proposition relative, proposition indépendante). Chaque réseau est un ensemble d'états réunis par des arcs (4 types : CATEGORY, JUMP, SEEK et SEND), ce qui représente globalement 150 conditions et 60 actions.

Aspects informatiques

Les dictionnaires sont stockés sur des disques en ligne. Distincts pour la langue source et la langue cible, les enregistrements d'une longueur fixe de 160 octets sont liés à un nombre de 12 chiffres qui permet d'y accéder. Ils contiennent des mots simples et des groupes de mots.
- *Les unités de substitution* : (de 2 à 5 mots, ex : By leaps and bounds). Si une telle unité est repérée, les enregistrements du dictionnaire correspondant à chaque mot sont remplacés par un seul enregistrement pour toute la séquence. La traduction figure dans un enregistrement unique du dictionnaire cible. Ce type d'unité permet de traduire correctement des noms d'institution, des titres de publication, des idiomes, des expressions techniques...).
- *Les unités d'analyse* : (de 2 à 5 mots) qui n'ont pas de contrepartie dans le dictionnaire cible et indiquent à l'analyseur les limites d'un syntagme, d'une unité d'analyse ou si les mots appartiennent ou non à une unité. (ex : *drinking water* permet d'analyser *the children have been drinking water with a high fluoride content*).
- *Les unités de substitution différée* pour l'analyse des formes verbales disjointes (ex : *look up, carry out...*).

---

(1) W.A. WOODS : Augmented Transition Networks for Natural Lan guage Analysis, report N C51 to the National Science Foundation , BBN, Cambridge Ma, 1969
(2) W. A. WOODS : An experimental Parsing System for Transition Network Grammars in R. RUSTIN (ed.) : Natural Language Proces sing, Algorithmics Press, New York, 1971, pp. 111 -154
(3) R. M. KAPLAN : A General syntactic Parser in R. RUSTIN (ed.) : Natural Language Processing, Algorithmics Press, New York, 1971, pp. 193-241

- *Les unités de transfert* (dictionnaire source) ne sont utilisées qu'après l'analyse pour indiquer la possibilité de donner plusiers traductions et effectuer le choix[1].

Règles de grammaire

Pour SPANAM, elles sont de deux types :

- *Pattern Matching* : reconnaissance et réorganisation des phrases nominales. Les schémas grammaticaux peuvent être stockés et réactualisés sans que cela n'implique une recompilation du programme.

- *Transformations* : Identification et synthèse des groupes verbaux. Chaque groupe de règles est testé pour chaque phrase. La structure impliquée par chaque règle est comparée avec la chaîne testée. En cas de correspondance, elle est appliquée et entraîne une permutation, une concaténation, une destruction, ou une substitution des mots ou groupes de mots concernés.

Pour ENGSPAN, la configuration du réseau indique les séquences de constituants possibles. La construction des noeuds dans la structure et les fonctions sont déterminées selon les actions représentées par les arcs. Les conditions et les actions sont contenues dans des modules qui font partie du programme compilé.

Algorithme d'analyse

Dans ENGSPAN, l'analyseur fonctionne séquentiellement de haut en bas et de gauche à droite, avec des retours en arrière. Il s'arrête dès qu'il aboutit à une solution. Le parcours effectué dans le réseau dépend des arcs affectés pour chaque état, des informations disponibles sur la structure de la phrase et des codes associés aux entrées de dictionnaire consultées. Dans une première étape, des procédures ont permis de stocker des données sur la ponctuation ainsi que sur la présence de majuscules et de signes diacritiques. L'analyseur traite les mots un par un et teste tous les arcs pour chaque état. Les arcs possibles sont placés sur une pile. L'arc qui est au sommet de la pile est emprunté. L'analyse se poursuit alors, aussi longtemps que se présentent d'autres arcs. S'il n'y a plus d'arc, le parser revient en arrière. L'analyse aboutit lorsque l'on atteint l'extrémité de la chaîne et un état final du réseau. Si l'analyseur ne parvient pas à parcourir le réseau, il y a échec. Pour le traitement des relatives et des interrogatives indirectes, le programme dispose d'une liste qui fonctionne comme une mémoire et dans laquelle il copie la phrase rencontrée. Il utilise cette copie lorsqu'il rencontre la rupture de construction. Les retours en arrière utilisent également ce procédé.

Développé sous la forme d'un module indépendant écrit en PL/1, l'analyseur ATN est compatible avec le système SPANAM. La grammaire de réseau fonctionne avec un run-time, ce qui permet d'expérimenter différents types de réseau sans recompiler le programme. L'analyseur vient d'être incorporé dans le système SPANAM.

La figure suivante illustre les relations entre les composantes principales de l'algorithme de traduction et les structures de données utilisées.

---

(1) M. VASCONCELLOS, M. LEON : SPANAM and ENGSPAN : Machine Translation at the Pan American Health Oragnization in J. SLOCUM (ed.) : Machine Translation Systems, Cambridge University Press, 1988, p. 211

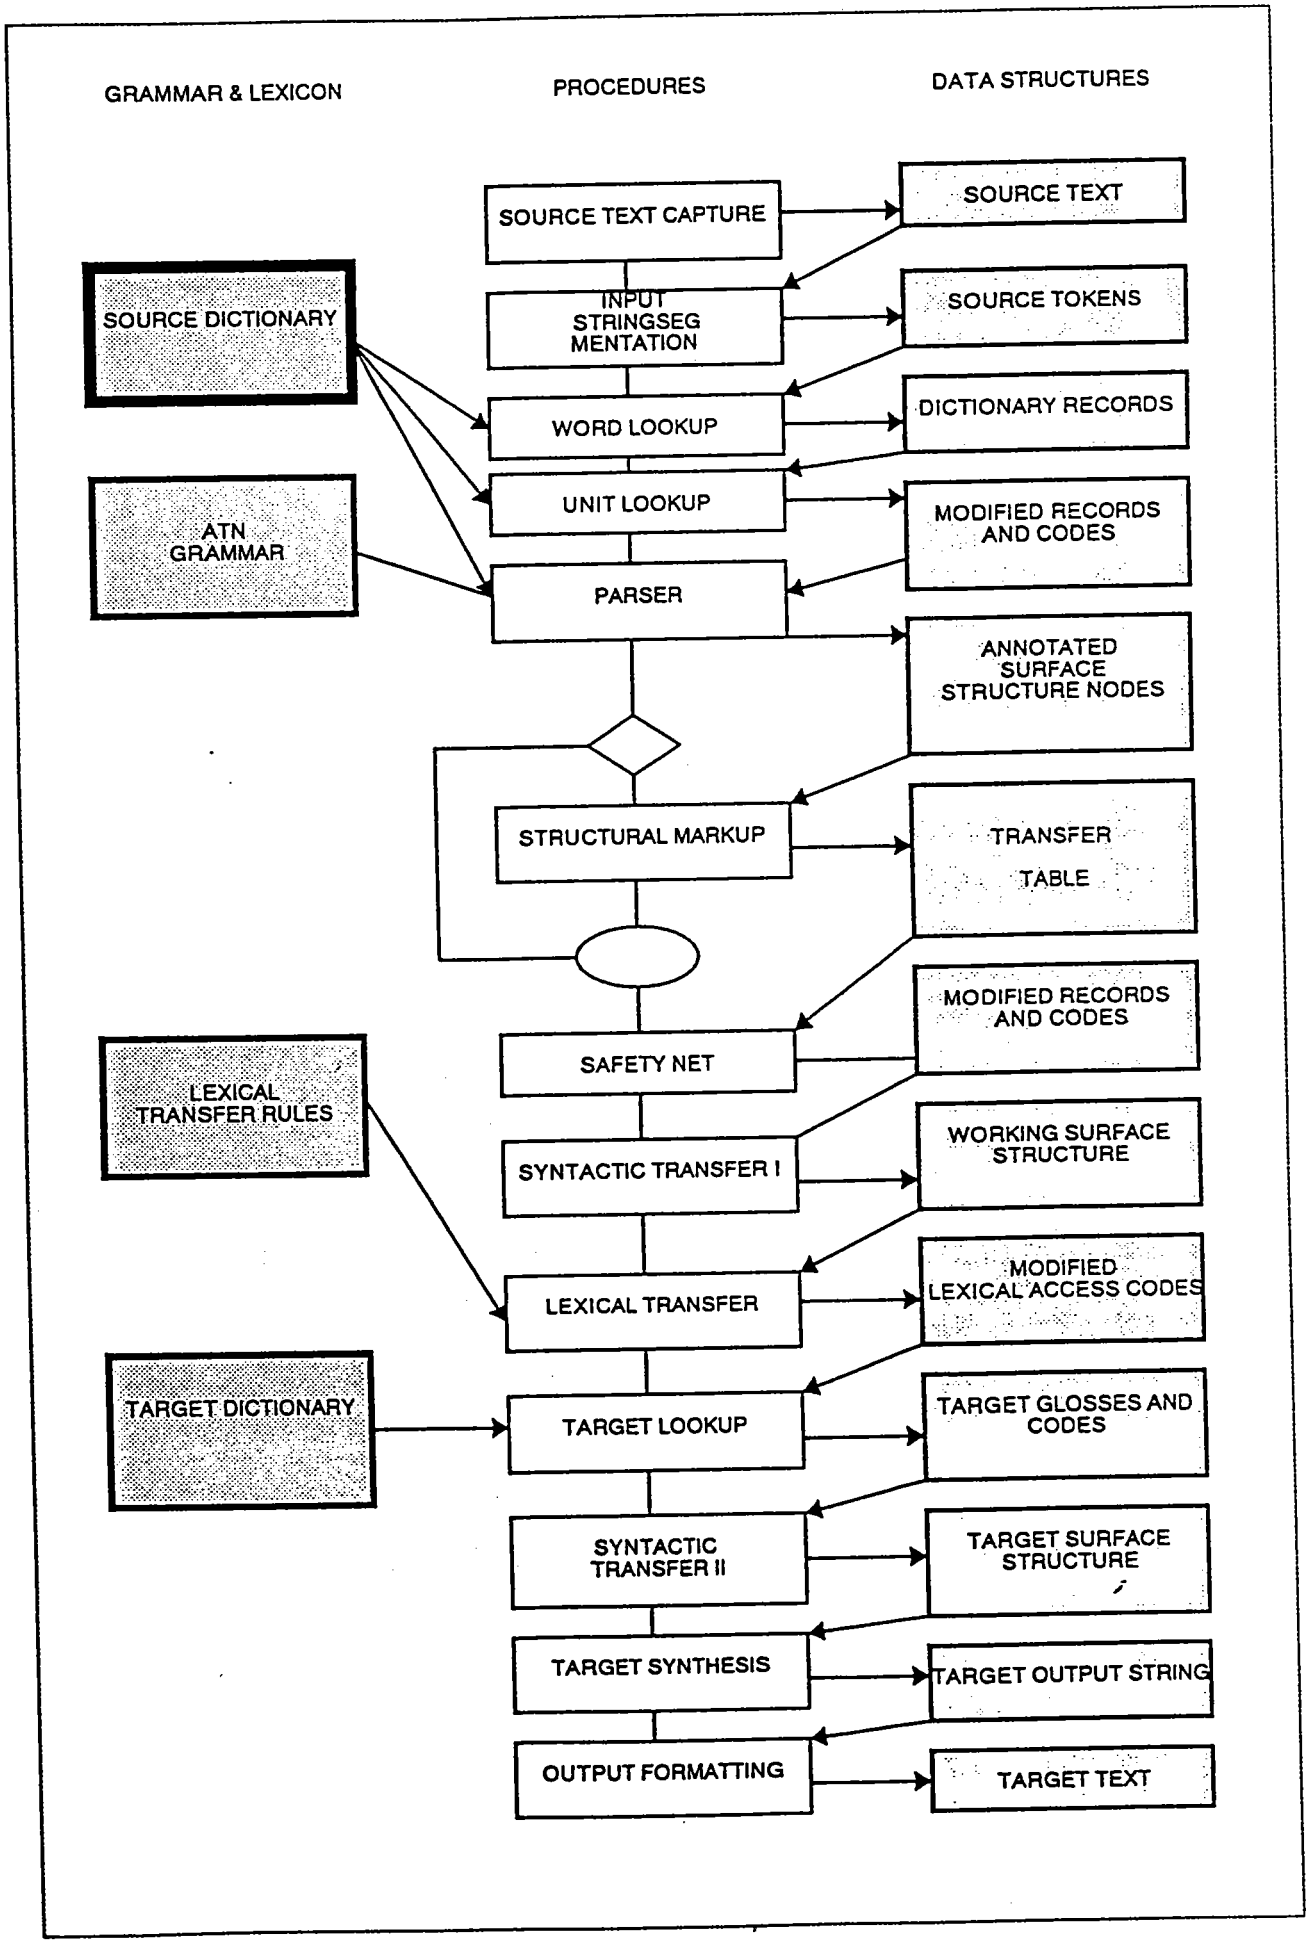
GRAMMAR & LEXICON
PROCEDURES
DATA STRUCTURES
SOURCE TEXT CAPTURE
SOURCE TEXT
SOURCE DICTIONARY
INPUT STRINGSEG MENTATION
SOURCE TOKENS
WORD LOOKUP
DICTIONARY RECORDS
UNIT LOOKUP
MODIFIED RECORDS AND CODES
ATN GRAMMAR
PARSER
ANNOTATED SURFACE STRUCTURE NODES
STRUCTURAL MARKUP
TRANSFER TABLE
MODIFIED RECORDS AND CODES
SAFETY NET
LEXICAL TRANSFER RULES
SYNTACTIC TRANSFER I
WORKING SURFACE STRUCTURE
LEXICAL TRANSFER
MODIFIED LEXICAL ACCESS CODES
TARGET DICTIONARY
TARGET LOOKUP
TARGET GLOSSES AND CODES
SYNTACTIC TRANSFER II
TARGET SURFACE STRUCTURE
TARGET SYNTHESIS
TARGET OUTPUT STRING
OUTPUT FORMATTING
TARGET TEXT

Afin de livrer une traduction dans tous les cas, y compris lorsqu'une analyse échoue, l'algorithme applique une stratégie de secours ("safety net") qui doit permettre au module de transfert de fonctionner même si les informations que lui fournit le module d'analyse sont incomplètes.

Module de transfert

Lorsque l'analyse est terminée, l'étape suivante consiste à examiner la structure de surface qu'elle révèle. L'information qui en découle sera utilisée pour la traduction. Les marques de cette structure de surface sont rangées dans une table qui contient des indications sur les fonctions syntaxiques et sémantiques des principaux constituants de la phrase.

Le tranfert lexical : Les unités d'analyse (AUs) et les unités de transfert (TUs) déterminent le choix des termes dans la langue cible. Les *unités d'analyse* sont des entrées composées de plusieurs mots, qui figurent dans le dictionnaire source, sans qu'il n'y ait de correspondance avec le dictionnaire cible. Les *unités de transfert* indiquent les traductions possibles d'un mot ou d'un groupe de mots selon le contexte. Elles sont stockées dans le dictionnaire source et n'interviennent qu'une fois l'analyse terminée. Si le contexte l'implique, la clé de correspondance avec le terme de la langue cible est modifiée et le système retiendra la bonne traduction. Le transfert s'accomplit en remplaçant l'entrée de l'anglais source (LEX) par l'équivalent dans le dictionnaire espagnol cible, en tenant compte des codes qui pourraient indiquer des pluriels irréguliers, des particularités d'ordre morphologique ou encore l'existence de plusieurs équivalences et entraîner le recours aux microglossaires.

Le transfert syntaxique : La stratégie retenue est d'utiliser la structure de surface de la phrase source pour obtenir après traitement une phrase grammaticalement et stylistiquement correcte. Le système respecte l'ordre de la phrase dans la mesure du possible. Les règles de transfert syntaxiques sont de trois types, elles peuvent en effet être liées au lexique (cible ou source) ou en être indépendantes, dans ce cas, elles permettent de convertir une structure de surface d'une langue vers l'autre, par transformation.

Module de synthèse

Lorsque le transfert est terminé, des indications associées à chaque entrées lexicales permettent d'ajouter les morphèmes grammaticaux (terminaisons, inflections), des suffixes et/ou des préfixes dans certains cas et des mots outils (articles définis, indéfinis, prépositions...).A la synthèse du verbe succèdent ensuite la génération des formes pronominales de surface (réfléchies, objet direct, objet indirect), la correction du groupe nominal (genre et nombre), l'insertion de mots-outils, l'introduction de variantes phonologiques et la mise en place des majuscules et des signes diacritiques.

Exemples de traduction

Les exemples qui suivent sont extraits de J. SLOCUM : Machine Translation systems, pp. 233-235, Cambrige University Press, 1987.

Les phrases qui ont été complètement analysées sont marquées par "OK", celles qui n'ont été que partiellement analysées par "PP" et celles qui n'ont pu être analysées par "NO".
A l'application d'une règle de transfert correspond "TU" et à l'absence d'un mot dans le dictionnaire "SD".

The mothers who lived within a 5-mile radius were asked to bring their children to the vaccination center.	OK TU TU	A las madres que vivían dentro de un radio de 5 millas se les pidió que trajeran a sus hijos al centro de vacunación.
Often the cold chain is thought to refer only to the refrigeration of vaccine.	OK	A menudo la cadena de frío se piensa que se refiere solamente a la refrigeración de vacuna.
The relationship between dietary fat and mamary carcinogenesis in experimental models will be presented and, finally, the possible relationship between dietary fat and hormones will be discussed.	OK	Se presentará la relación entre grasa en la alimentación y carcinogénesis mamaria en modelos experimentales y, finalmente, se tratará la relación posible entre grasa en la alimentación y hormonas.
A privately organized by publicly funded foundation is responsible for primary health care in the interior of the country where 10% of the population lives.	OK	Una fundación privadamente organizada pero públicamente financiada es responsable de atención primaria de salud en el interior del país donde vive un 10% de la población.
The National Program for Drinking Water Supply has the goal to expand to full coverage the already existing distribution system.	PP	El Programa Nacional para Abastecimiento de Agua Potable tiene la meta para ampliar a cobertura total el sistema de distribución ya existente.
Other analyses will test the epidemiologic association between 1) ethylene oxide exposure and leukemia and 2) *PAH exposure in the cola hydrogenation process and cancer of the respiratory system, urogenital system, and the skin.	SD NO	Otros análisis examinarán la asociación epidemiológica entre 1) la exposición de óxidos de etileno y leucemia y 2) la exposición de PAH en el proceso de hidrogenación de carbón y cáncer del aparato respiratorio, aparato urogenital, y la piel.

Sample Input		ENGSPAN Output
We request that each potential participant send biographical information and a 100-word abstract of the demostration or paper, so that we can select those who will make the greatest contribution to a useful exchange of information at the symposium.	OK TU	Solicitamos que cada participante potencial envíe información biográfica y un resumen analítico de 100 palabras de la demostración o documento, para que podamos seleccionar los que harán la contribución mayor a un intercambio útil de información en el simposio.
The task of hiring and assigning staff to perform the work is one which must be completed prior to training.	OK	La tarea de contratación y asignación de personal para realizar el trabajo es una que se debe completar anterior a adiestramiento.
Laboratory studies have shown marijuana to impair perceptual and perceptual-motor functions important to driving.	OK TU	Estudios de laboratorio han revelado que marihauna deteriora funciones de percepción y perceptomotrices importantes a conducción.

2.3.3.3.7 TAUM (Traduction Automatique de l'Université de Montreal)

Soutenu par le gouvernement canadien, le projet TAUM voit le jour en 1965 à l'université de Montréal. Les programmes de traitement automatique sont rédigés en FORTRAN et tournent sur un CDC 6600 puis sur un CYBER 173.
Après une période de recherche décousue, on lui assigne un objectif en 1965 : traduire automatiquement les bulletins météorologiques de l'anglais vers le français. Le prototype METEO est présenté en 1976. Il sera installé en 1977 et remportera le succès que l'on sait.
Un deuxième objectif est fixé en 1977 : traduire automatiquement des manuels de maintenance aéronautique (90 millions de mots) de l'anglais vers le français. Le système AVIATION s'enrichit d'un module d'analyse sémantique mais les délais impartis et les coûts démesurés conduisent les responsables à abandonner le projet.

2.3.3.3.7.1 TAUM-METEO[1]

Mis au point par le groupe TAUM en 1975-1976, le prototype a été développé dans un langage spécialisé (Systèmes-Q) et commercialisé par la société *Consultants en linguistique computationnelle Ltée* sous le nom de METEO 1, après une année d'importants travaux qui lui ont permis de passer de 40% à 80% des phrases effectivement traduites.

---

(1) M. CHEVALIER, J. DANSEREAU, G. POULIN : *TAUM-MTEO : Description du système,* Groupe TAUM, Université de Montréal, Montréal, 1978

La société *J. Chandioux experts-conseils inc.* développe un nouveau langage de programmation (GramR) et après avoir démontré la faisabilité d'une traduction automatique sur microordinateur, construit un nouveau système, METEO 2, qui remplacera METEO 1 en 1983, parce que plus performant, moins coûteux, plus fiable et plus convivial. Il est actuellement loué par le *Bureau des Traductions* sous une formule clé-en-main (ordinateurs, logiciels, service 24 heures par jour, mise à jour des dictionnaires).

En 1950, le problème de la traduction automatique était assimilé à un simple problème de décryptage. Les systèmes de première génération se composaient d'un énorme dictionnaire et s'appuyaient sur une analyse de contexte (deux mots avant et après le mot courant). Les limites de SYSTRAN sont alors notoires et le rapport ALPAC donne un coup d'arrêt à la recherche sans tenir compte d'une deuxième génération de systèmes qui présentent des caractéristiques fondamentales nouvelles. Ils sont programmés dans un langage évolué accessible aux linguistes, l'analyse de la phrase est complète et ils travaillent en trois étapes (l'analyse, le transfert et la génération) qui correspondent à la compréhension du texte, à la transposition de l'idée et à la formulation du résultat en langue cible.

Langage de programmation GramR

Fortement influencé par les travaux du GETA (Groupe d'Etudes pour la Traduction Automatique) à Grenoble, ce langage est un transducteur de chaînes d'arborescences paramétrées qui permet au linguiste initié au formalisme de la grammaire transformationnelle développée par CHOMSKY de définir un modèle linguistique en écrivant des règles. Le modèle est compilé puis évalué sur des exemples.
Premier langage de deuxième génération à fonctionner sur microordinateur en 1982, les applications de GramR dépassent le cadre de la traduction automatique, avec l'E.A.O. (Enseignement Assisté par Ordinateur et mise au point de didacticiels), les correcteurs orthographiques (SpellR), les interfaces en langue naturelle (Easy-Dos). Le langage est, de plus, disponible en versions MS-DOS, UNIX 68 000 et VAX VMS.

Analyse de la phrase

Le texte présente des caractéristiques qui ne facilitent pas la tâche, contrairement à ce que l'on pourrait imaginer : Entièrement en majuscules, pratiquement sans ponctuation. Les mots qui servent de pivot dans une analyse classique sont souvent absents (conjonctions, prépositions, articles...). L'analyseur est de ce fait plus orienté vers la sémantique, ce qui n'est pas une gageure, tant il est vrai qu'une sémantique fermée (météorologie) peut être mieux cernée qu'une sémantique ouverte.

On distingue cinq phases :

- *la pré-édition* : Elimination des redondances ou des mots non significatifs, normalisation de certains énoncés, identification des expressions idiomatiques, développements des abréviations.
- *le dictionnaire* : il associe à chaque mot sa catégorie syntaxique et des informations sémantiques et morphologiques nécessaires au fonctionnement des modules d'analyse suivants. Il contient environ 2000 mots et expressions.
- *l'analyseur* : les groupes nominaux sont repérés et classés en conditions météorologiques, en circonstanciels de temps et circonstanciels de lieu selon des compatibilités ou incompatibilités de classes sémantiques. L'analyse du groupe verbal vient ensuite, puis son intégration avec les groupes nominaux dans un énoncé.
- *la génération syntaxique* : les grammaires utilisées opèrent une série de transformations sur les résultats de l'analyse et génèrent les mots cibles dans un ordre correct.

- la génération morphologique : pour les accords en genre et en nombre, les problèmes d'élision et de contraction et les ajustements stylistiques.

Le transfert n'apparaît pas explicitement dans cette description. Il s'effectue en réalité au niveau des dictionnaires et essentiellement de l'analyseur, puisque l'analyse est plus sémantique que syntaxique.

L'environnement

Un ensemble de modules complète les grammaires écrites en langage GramR.

- GERTELEX : capte le bulletin météo sur la ligne TELEX, note son identification (heure d'arrivée, nombre de mots...) et le soumet à la traduction.
- EXEMETEO : applique les grammaires, relève le nombre de marques de révision et soumet le bulletin à la révision.
- SUPRVIZR : affiche en permanence l'état des files d'attente en ce qui concerne la traduction, la révision et la transmission.
- REVISEUR : permet au traducteur de réviser la traduction très rapidement (éditeur spécialisé), note le nombre de corrections, met le texte en format TELEX, relève l'heure et met le bulletin dans la file d'attente pour être transmis.
- GERTELEX : programme de communication, est chargé d'expédier le bulletin.

Le système tourne sur un micro équipé d'un processeur 68010 et d'un disque dur de 5 Mo, avec une mémoire centrale de 512 Ko. La liaison avec la ligne TELEX 300 bauds et le terminal intelligent affecté à la révision est assurée par une interface de communication série multi-ports. Le système d'exploitation est une variante d'UNIX appelée CROMIX. La programmation est réalisée en FORTRAN IV. Le temps de panne est inférieur à un jour par an !

Le système traduit actuellement les bulletins des stations de Vancouver, Edmonton, Calgary, Regina, Toronto et Halifax, ce qui correspond à une moyenne de 30000 mots par jour, soit 8,5 millions de mots par an. Il faut souligner que ce sytème, un des plus anciens en service, donne entière satisfaction à ses utilisateurs (90%-95% de phrases correctement traduites). Les erreurs d'analyse peuvent être imputées à des défauts de communication, des fautes d'orthographe ou des lacunes dans le dictionnaire. Il démontre que dans un certain contexte, la traduction automatique peut devenir réalité. Une version français-anglais fonctionne depuis le début de l'année 1990 et traduit les bulletins de tout le Quebec.

3.3.3.3.7.2 TAUM-AVIATION[1]

Après que le groupe TAUM ait mis au point différents prototypes qui aboutiront à une première application, le système TAUM-METEO, un second projet mobilisera ses efforts. L'objectif est beaucoup plus audacieux car l'ampleur de la tâche implique un renforcement de l'équipe en personnel (7 chercheurs en 1976, 20 en 1979) et en moyens techniques (nouveaux langages de programmation, LEXTRA et SISIF). Les travaux démarrent en 1976 et aboutissent à la présentation d'un prototype en 1979, limité à la traduction des manuels de maintenance des systèmes hydrauliques. Une évaluation du système en 1980 dénonce la non-rentabilité du programme et entraîne lá dissolution du groupe.

---

(1) **P. ISABELLE, L. BOURBEAU, M. CHEVALIER, S. LEPAGE** : *TAUM-AVIATION : description d'un système de traduction automatisée de manuels d'entretien en aéronautique*, COLING-78, Bergen

Le noyau du système est indépendant des couples de langues traités, les données linguistiques sont traitées séparément des programmes. Dans le cas présent, il ne s'agit que du couple anglais-français. Les descriptions linguistiques externes sont cependant distinctes de la langue générale et ne concernent que la langue spécifique aux manuels de maintenance (sublanguage)[1].
Installé sur un CYBER 173 avec le système d'exploitation NOS/BE 1.4, TAUM-AVIATION a été conçu pour être indépendant du matériel. Une grande partie des données sont compilées en un code objet interprétable par un run-time. Le tableau suivant indique les tailles de sfichiers compilés.

Component	Compiled code (6-bit chars)		Runtime req's (60-bit words)
	(a)	(b)	
Pre-processing	60K	15K	34K
Morphological analysis	77K	48K	40K
Source language dictionary	1958K	72K	40K
Syntactic/semantic analysis	205K	56K	120K
Bilingual dictionary	1919K	107K	40K
Syntactic transfer/synthesis	113K	63K	56K
Morphological synthesis	99K	64K	24K
Post-processing	43K	15K	34K

(a) : données linguistiques compilées
(b) : interpréteur compilé pour (a)

Le tableau suivant donnne la taille des programmes utilisés pour compiler les données linguistiques. La taille est exprimée en mots de 6 bits.

Metalanguage	Used for	Size (x 6 bits)
SISIF	pre- and post-processing	43K
REZO	syntactic/semantic analysis	155K
LEXTRA	lexical transfer	130K
SYSTEMES-Q	structural transfer; syntactic synthesis	28K

Les dictionnaires ne contiennent que les formes non fléchies (entrées classiques dans un dictionnaire conventionnel). Lorsque le projet a été stoppé, le dictionnaire de la langue source (anglais) contenait 4054 entrées représentant le noyau du vocabulaire de maintenance et un sous-ensemble de vocabulaire propre à l'hydraulique. Plus des 2/3 de ces entrées avaient une correspondance dans le dictionnaire bilingue anglais-français.

Fonctionnement

La sortie devait être exploitable directement pour la photocomposition, ce qui a nécessité un traitement initial du format et un enregistrement des codes correspondants. Le processus de traduction est entièrement automatique mais peut être interrompu avant la

---

(1) J. LEHRBERGER : "Automatic Translation and the Concept of Sublanguage", in : R. KITTREDGE, J. LEHRBERGER (eds.), *Sublanguage : Studies of Language in Restricted Semantic Domains*, De Gruyter, Berlin, 1982, pp. 81-106

interrompu avant la consultation des dictionnaires pour lister les premiers résultats du découpage. La traduction obtenue en fin de traitement nécessite la révision d'un traducteur. La conception du système ne prévoit pas la prise en compte des analyses partielles, de sorte que 20% à 40% des phrases ne sont pas traitées ! Système de deuxième génération, il obéit au schéma classique : analyse, transfert et synthèse. L'organisation de la plupart de ses composantes s'appuie sur des critères linguistiques. L'algorithme est du reste distinct des données concernant les langues.
La méthode du transfert a été retenue. Les règles de traduction ne peuvent pas être appliquées à la chaîne d'entrée mais plutôt à un objet formalisé représentant une description de la structure de son contenu. Le texte source est représenté dans un langage intermédiaire (la structure normalisée) avant l'application des règles liées à la langue cible. Dans TAUM-AVIATION, ce langage intermédiaire dépend de la langue et renvoie aux structures profondes de la phrase par des marques sémantiques. L'application d'une grammaire indépendante du contexte fournit une liste des structures profondes admises (les composants de base pour la langue source et la langue cible) et conduit à un certain degré d'indépendance. Les items lexicaux ne sont pas modifiés et le module de transfert assure le passage à la structure en langue cible.
Les éléments qui composent les trois modules correspondent à des divisions classiques de la linguistique (lexique, morphologie, syntaxe et sémantique). Le schéma suivant représente la structure du système :

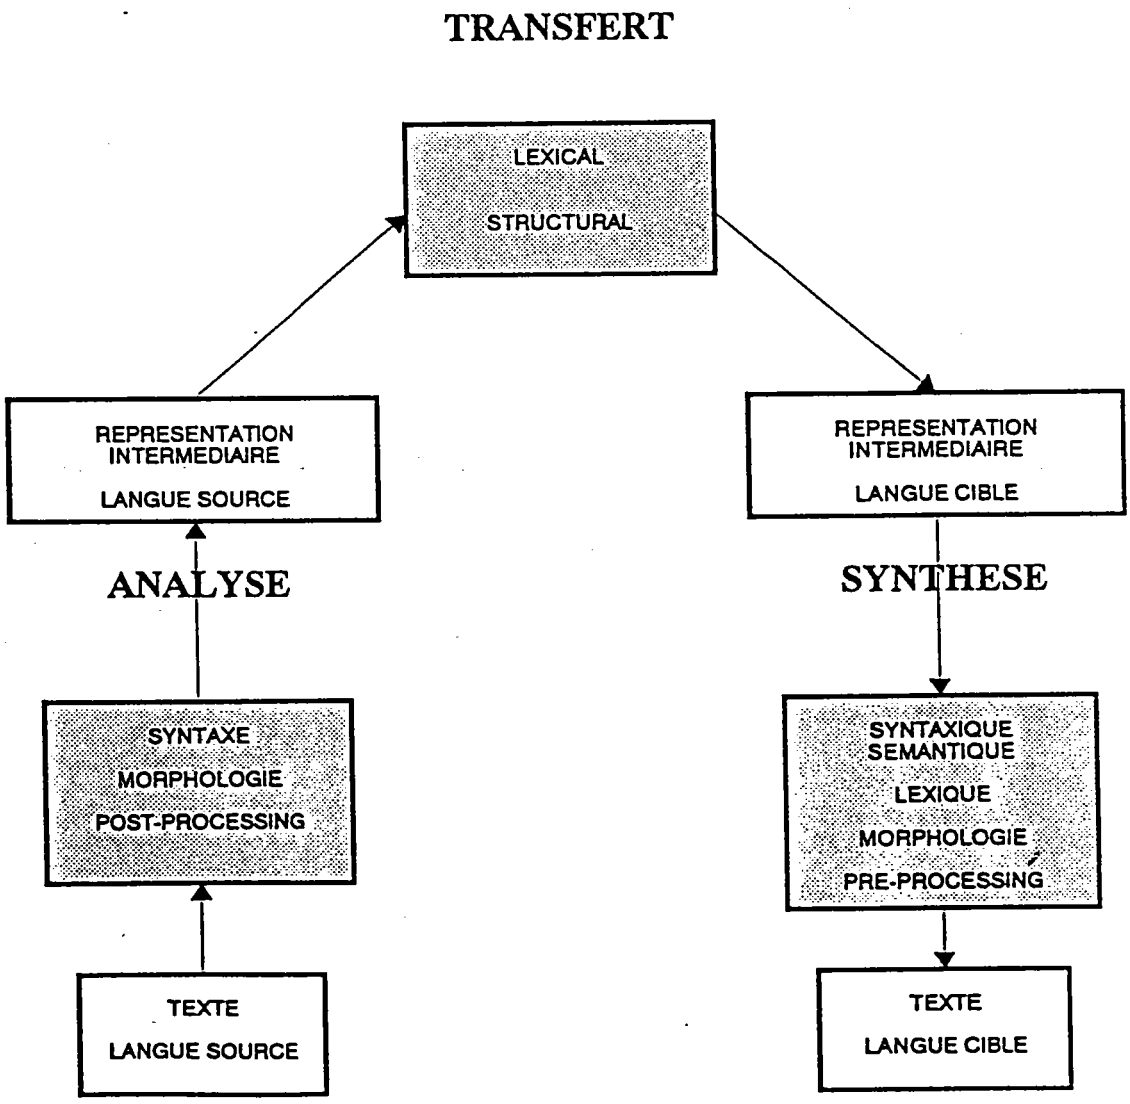

Analyse

Le contexte de l'analyse est limité à la phrase.

- *Pré-processing* : Les mots sont repérés et les unités de traitement isolées. Les règles du module correspondant, qui fonctionne comme un automate déterministe d'états finis, sont écrites en langage SISIF et compilées en structures de listes.

- *Morphologie* : Deux programmes écrits en PASCAL traitent les règles et les exceptions de la morphologie anglaise, n'abordent pas les phénomènes de dérivation mais traitent certains phénomènes de composition.

- *Lexique* : SYDICAN, le dictionnaire de langue source, rassemble les règles lexicales associées à la chaîne de base. Elles sont compilées. Pour le dictionnaire bilingue, le langage LEXTRA permet aux règles lexicales de transfert de réaliser des transformations complexes de structures arborescentes en associant à chaque item lexical un ensemble de transformations d'arbre. Il utilise les éléments de la représentation intermédiaire (règles de grammaire indépendante du contexte) comme des données, ce qui garantit la validité des manipulations d'arborescence. Les règles de LEXTRA sont compilées dans des structures de liste. L'interpréteur recherche la structure des items lexicaux de langue source, relève les règles lexicales associées et les applique à l'arbre.

- *Syntaxe et sémantique* : la grammaire est écrite en REZO[1]. Ce métalangage s'appuie sur la théorie des réseaux de transitions augmentés mais s'écarte légèrement des ATNs de WOODS. REZO n'assure pas l'analyse morphologique, les noeuds sont des symboles complexes qui incluent des éléments sur lesquels il est posible d'effectuer des opérations booléennes, il regroupe un certains nombre de primitives qui pourront être comparées aux structures arborescentes. Alors qu'à chaque état d'un réseau toutes les transformations sont testées, REZO introduit la notion d'états déterministes dans lesquels on n'emprunte que la première transition testée. Il accorde d'autre part un statut spécial aux états qui peuvent être appelés de façon récursive. La grammaire est compilée pour tourner sur une machine virtuelle simulée par un interpréteur. L'analyse est descendante, de gauche à droite.

Le traitement sémantique filtre les structures syntaxiques et élimine ainsi le maximum d'ambiguïtés. Il associe à chaque noeud de l'arbre des marques sémantiques pour les règles de transfert. Le mécanisme essentiel repose sur l'élaboration d'un ensemble de restrictions destinées à éliminer les ambiguïtés lexicales et les ambiguïtés structurales induites par les règles syntaxiques. Les marques assignées à un noeud peuvent être transmises par héritage.

Transfert

En principe, les structures manipulées ne sont pas ambiguës. Le module (Systèmes-Q) met en relation les items de la langue source et de la langue cible. Des mécanismes transformationnels interviennent au niveau lexical.

Synthèse

- *syntaxique* : une grammaire transformationnelle du français produit une chaîne de termes auxquels sont associées des informations concernant les flections correctes.

---

(1) G. STEWART : *Le langage de programmation REZO*, M.Sc. thesis, Université de Montréal, Montréal, 1975

(2) G. STEWART : *Spécialisation et compilation des ATNs : REZO*, COLING-78, Bergen, Norvège, 1978

- *morphologique* : le module détermine les finales de mot (déclinaison du français et liste des exceptions).
- *post-processing* : reformatage du texte conformément au format du texte source

Informatique
La construction du système est beaucoup plus complexe que pour TAUM-METEO, la philosophie retenue consistant à créer des outils adaptés à chaque tâche, dans un souci d'efficacité. L'hétérogénéité de la programmation explique sans doute, pour une part, la difficulté de l'entreprise. Les Systèmes-Q ne peuvent pas manipuler les arbres dont les noeuds sont des symboles complexes. Les compilateurs et les interpréteurs sont écrits en FORTRAN alors que d'autres modules sont écrits en PASCAL...

Evaluation du système
En 1980, une expertise réalisée par A. GERVAIS[1] fixe le seuil de rentabilité à un volume de 6 millions de mots par an. Pour atteindre cet objectif, il est indispensable d'adapter le système à d'autres domaines, ce qui entraînerait de nouveaux coûts. Dans ces conditions, TAUM-AVIATION ne peut concurrencer la traduction manuelle. Le projet est arrêté.

Exemples de traduction :

Texte d'entrée :

HYDRAULIC PRESSURE IN-LINE RELIEF VALVE

(See figures 2-4 and 2-5.)

30 Identical interchangeable hydraulic pressure in-line relief valves (in-line relief valve) are provided for each ac hydraulic pump and for the dc hydraulic pump. The in-line relief Valves are located in the hydraulic service center. Those for the No. 1, No. 1A, and No. 1B ac and dc hydraulic pumps are on the left side next to the No. 1 service centre assembly. The in-line relief valve for the No. 2 ac hydraulic pump is incorporated in the No. 2 service centre assembly.

31 The in-line relief valves are poppet-type, spring-loaded to the closed position. A pressure of 3450 psi impinging on the poppet is sufficient to overcome the opposing spring force, and the poppet will move from its knife-edge seat.

(1) A. GERVAIS : Evaluation of the TAUM-AVIATION Machine Translation Pilot System, Translation Bureau, Secretary of State, Ottawa, Canada, 1980

Traduction automatique brute :

CLAPET DE DECHARGE INCORPORE DE PRESSION HYDRAULIQUE

(Voir les figures 2-4 et 2-5.)

30 Les clapets de décharge incorporés interchangeables identiques de pression hydraulique (clapets de décharge incorporés) sont prévus pour chaque pompe hydraulique ca et pour la pompe hydraulique cc. Les clapets de décharge incorporés sont situés dans le compartiment hydraulique. Ceux pour les pompes hydrauliques ca et cc no 1, no 1A et no 1B sont du côté gauche à côté du bloc collecteur no 1. Le clapet de décharge incorporé pour la pompe hydraulique ca no 2 est intégré au bloc collecteur no 2.

31 Les clapets de décharge incorporés sont champignon, sont rappelés par ressort à la position fermée. Une pression de 3450 psi s'exerçant sur le clapet-champignon est suffisante pour vaincre la force de rappel du ressort et le clapet-champignon se déplacera de son siège en couteau.

Traduction révisée :

CLAPET DE DECHARGE INCORPORE DE PRESSION HYDRAULIQUE

(Voir les figures 2-4 et 2-5.)

30 *Des* clapets de décharge incorporés interchangeables identiques de pression hydraulique (clapets de décharge incorporés) sont prévus pour chaque pompe hydraulique ca et pour la pompe hydraulique cc. Les clapets de décharge incorporés sont situés dans le compartiment hydraulique. Ceux *des* pompes hydrauliques ca et cc no 1, no 1A et no 1B sont du côté gauche à côté du bloc collecteur no 1. Le clapet de décharge incorporé pour la pompe hydraulique ca no 2 est intégré au bloc collecteur no 2.

31 Les clapets de décharge incorporés, *du type* champignon, sont rappelés par ressort à la position fermée. Une pression de 3450 psi s'exerçant sur le clapet-champignon est suffisante pour vaincre la force de rappel du ressort et le clapet-champignon *s'écartera* de son siège en couteau.

2.3.3.3.9 TITRAN[1]

TITRAN a été développé à l'université de Kyoto, au Japon, en collaboration avec le groupe de Sarrebruck. Il ne traduit que les titres d'articles scientifiques et techniques, dans les couples anglais-japonais, japonais-anglais et japonais-français. Une version japonais-allemand fait l'objet d'un nouveau projet de collaboration avec l'université de Sarrebruck.

---

(1) S. MELI : "Informationsmarkt der maschinellen Übersetzung" in *Terminologie et Traduction*, Commission des Communautés Européennes, n°3, 1989, pp. 83-84

2.3.3.3.10 TITUS IV[1]

Système de traduction automatique et simultanée en quatre langues (français, allemand, anglais, espagnol), TITUS IV a été développé par des ingénieurs de l'Institut du Textile de France pour le traitement multilingue de bases de données scientifiques et techniques. Les données sont entrées dans l'une des quatre langues. Elles peuvent être récupérées et traduites automatiquement dans l'une des quatre langues. Afin de surmonter les difficultés de la T.A., certains chercheurs ont limité leur automate à une sémantique fermée (TAUM-METEO). Une deuxième voie consiste à contrôler la syntaxe du texte d'entrée en n'autorisant que certaines structures. TITUS IV manipule un langage à syntaxe contrôlée constitué de deux éléments de base :
- Pour la langue considérée, tout le vocabulaire d'un domaine (variable selon le domaine) et une partie du vocabulaire de base (commun à tous les domaines).
- un sous-ensemble de toutes les règles syntaxiques

Architecture

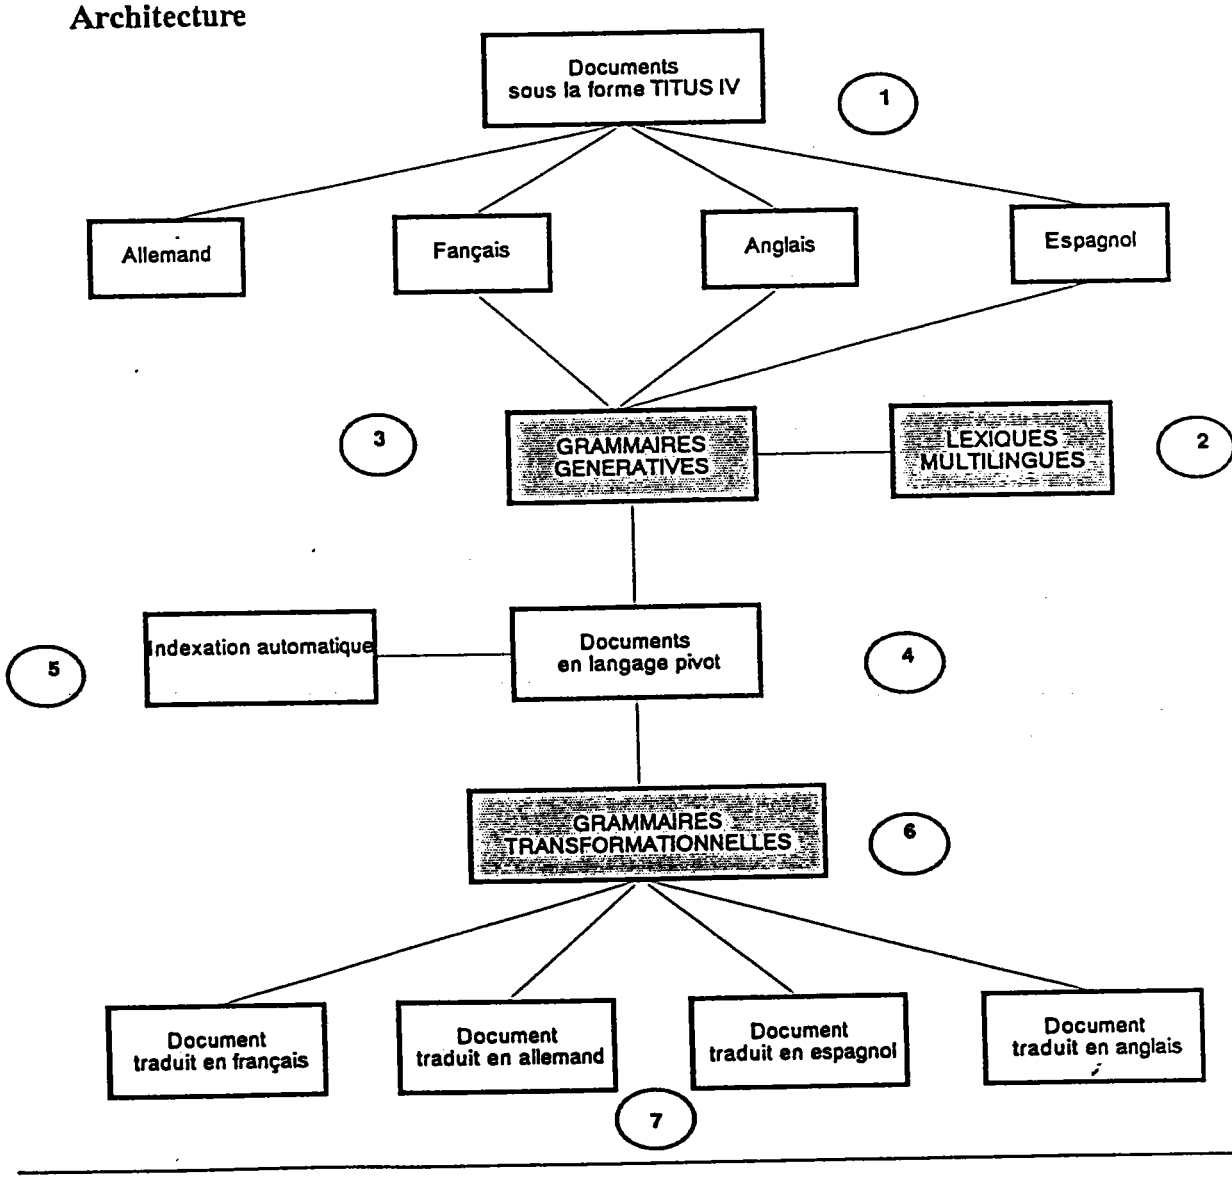

(1) J.-M. DUCROT : "Le système TITUS IV : Système de traduction automatique et simultanée en quatre langues in *TAO*, Observatoire des industries de la langue, DAICADIF, Actes du séminaire international (Paris, mars 1988), pp. 55-75

Pour qu'un texte soit accepté par le système, il doit être rédigé selon les règles de syntaxe préétablies, en français, allemand, anglais ou espagnol (1), et contenir des termes faisant obligatoirement partie du vocabulaire prévu (2). Lorque le texte est entré sur un terminal conversationnel, des lexiques multilingues et des grammaires génératives (3) en testent la validité lexicale et syntaxique. Toute erreur provoque l'affichage d'un message et l'intervention de l'opérateur. En détectant des mots-clés, ces grammaires effectuent en parallèle une indexation automatique du document (5). Le texte est ensuite réécrit en un langage pivot condensé (4). Dans ce langage binaire, chaque terme n'occupe pas plus de 10 octets. La phrase ainsi stockée est recodée dans une des langues en un temps qui varie de 0,03 à 0,8 s. selon l'ordinateur utilisé. Le texte en langage pivot est traité par des grammaires transformationnelles de sortie (6) qui en assurent la traduction automatique, l'affichage, l'édition ou l'enregistrement sur un support magnétique.

Le vocabulaire réunit les mots outils de chaque langue (déterminants, prépositions, conjonctions, adverbes, verbes auxiliaires...) qui font partie du système, et le vocabulaire proprement dit, stocké dans le lexique multilingue. Les correspondances entre langues ne sont pas toujours réalisées au niveau des items de sorte que l'élément du lexique n'est pas le terme mais l'**unité lexicale** (UL) qui peut contenir un terme ou une combinaison de termes. Les *unités lexicales substantives* figurent sous toutes leurs formes (genre, nombre, cas). Les *unités lexicales adjectivales* regroupent les adjectifs qualificatifs sans complément, les adjectifs qualificatifs avec complément possible et les participes passés adjectivés sous toutes leurs formes, y compris les formes irrégulières de comparatif et de superlatif. Pour les *unités lexicales verbales*, on a stocké l'ensemble des formes conjuguées. Les *unités lexicales adverbiales* regroupent les adverbes courants et les locutions adverbiales.

Le lexique multilingue peut être géré de façon interactive. Il est couplé à un lexique source qui réunit tous les paramètres nécessaires à une unité lexicale, sous forme de pages ou d'écrans : informations indépendantes de la langue en première page, paramètres relatifs au français en deuxième page, à l'anglais en troisième page, à l'espagnol en quatrième page et à l'allemand en cinquième et sixième page.

La syntaxe contôlée permet au système de traduire rapidement des textes en plusieurs langues. TITUS IV examine surtout la structure de surface. Les schémas de phrase acceptés constituent un modèle linguistique dans lequel doivent s'inscrire toutes les phrases. La version actuelle n'accepte qu'une proposition par phrase. La prochaine ver-sion traitera les phrases contenant jusqu'à trois propositions (principale, subordonnée). Le modèle de base du système *(le modèle basique de proposition)* correspond à la structure maximale possible d'une proposition. Il n'y a que le groupe nominal sujet (GNS) qui soit obligatoire.

Les groupes sont de deux types, selon leur élément principal :
- le groupe nominal (GN)
- le groupe verbal (GV)

On distingue :

- *le groupe nominal sujet* (GNS), le seul qui soit obligatoire, doit être formé d'au moins un substantif figurant dans le lexique, ou d'un pronom.

- *les groupes nominaux circonstanciels* (GNC1, GNC2, GNC3) sont optionnels. En nombre variable, de 0 à 3, ils commencent par une préposition ou une locution prépositionnelle

- *le groupe verbal* (GV) est facultatif. C'est une forme verbale simple ou composée, à la voix active ou passive.
- *le groupe verbal complément* (GVC) est un infinitif complément d'un verbe appartenant au GV précédent.
- *le groupe nominal complément* (GNV1) est au minimum un substantif ou un adjectif attribut, complément d'objet du verbe.
- *le groupe nominal complément* (CNV2), avec le(s) complément(s) d'attribution ou d'agent du verbe.
- *les groupes nominaux prépositionnels* (GNP1, GNP2, GNP3)

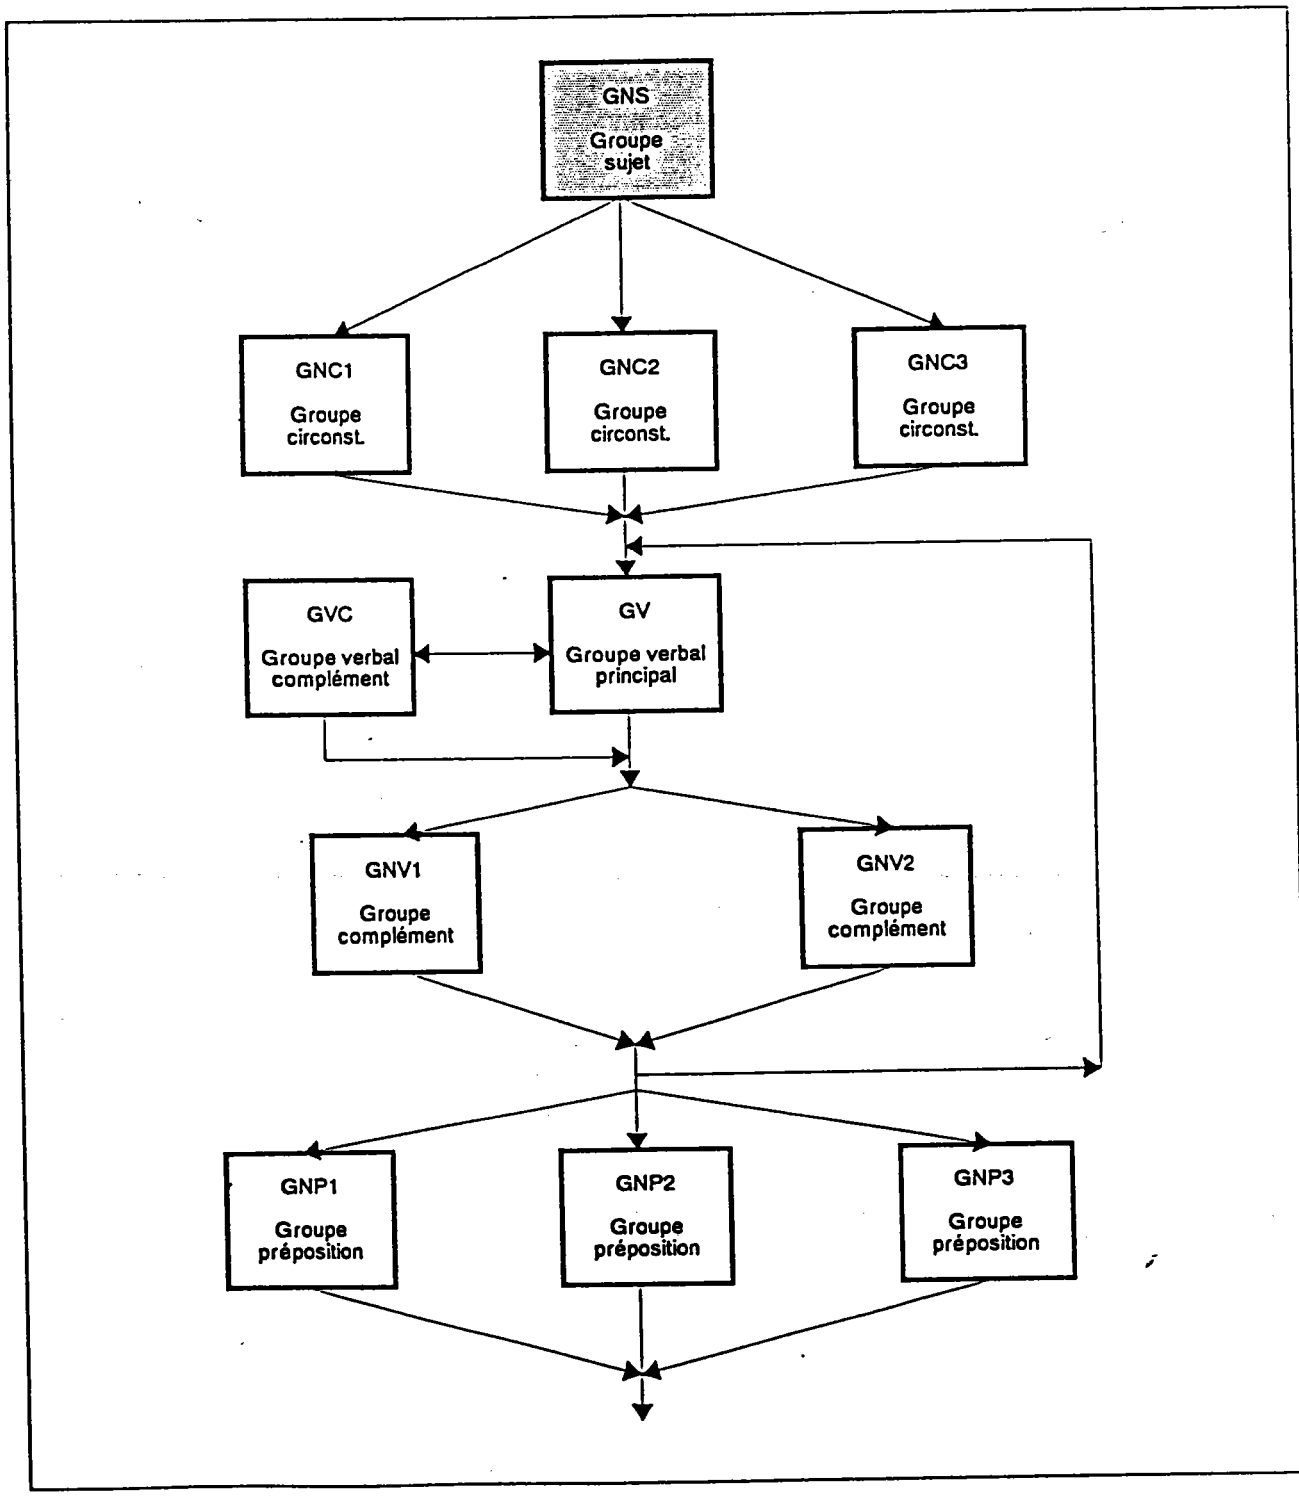

On constate que la phrase traitée dans TITUS IV se décompose en groupes nominaux et en groupes verbaux.

Le groupe nominal (GN) est formé d'un ou plusieurs sous-groupes nominaux (SN). (jusqu'à 15). Le sous-groupe nominal doit contenir un substantif au minimum auquel on ajoute des composants facultatifs (une préposition, un déterminant, un ou deux adjectifs simples avant ou après le substantif, une conjonction de coordination entre deux adjectifs, une ou deux appositions, un adjectif avec un complément (autre sous-groupe nominal...). Les relations autorisées entre sous-groupes sont les suivantes :

- sujet
- complément du nom
- complément de l'adjectif
- complément de comparaison

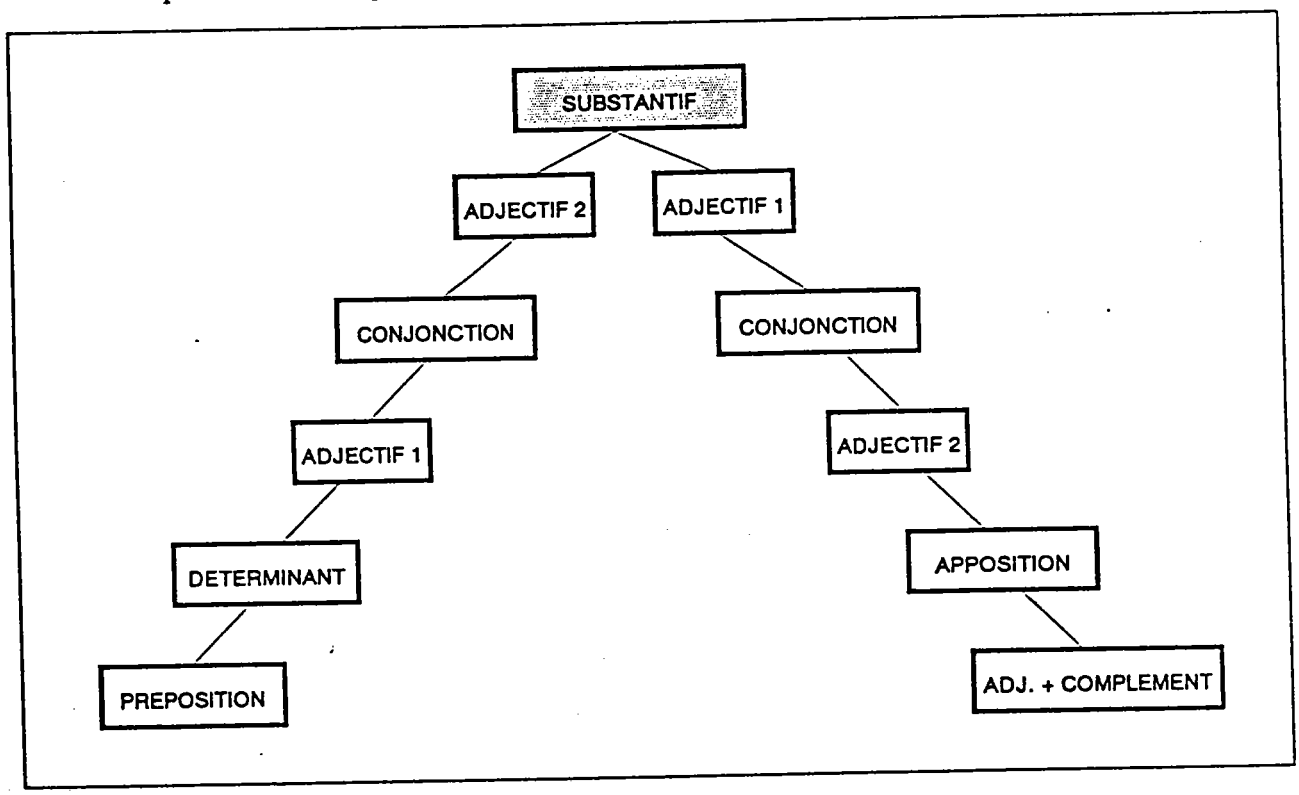

Le groupe verbal (GV) contient :

- un verbe auxiliaire ou modal qui fait partie des éléments outils, partie intégrante du système.
- un verbe du lexique

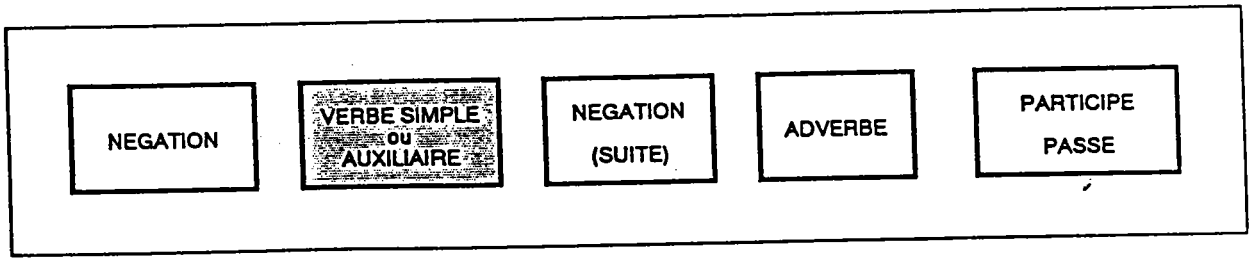

Le système est interactif. L'opérateur rédige les phrases, les introduit sur un terminal et obtient leur traduction instantanément. Il peut corriger ses fautes au fur et à mesure. De

même, il peut aider la machine dans son travail de traduction, en levant les ambiguïtés qui posent problème et font l'objet d'un dialogue à l'écran comme ci-dessous[1] :

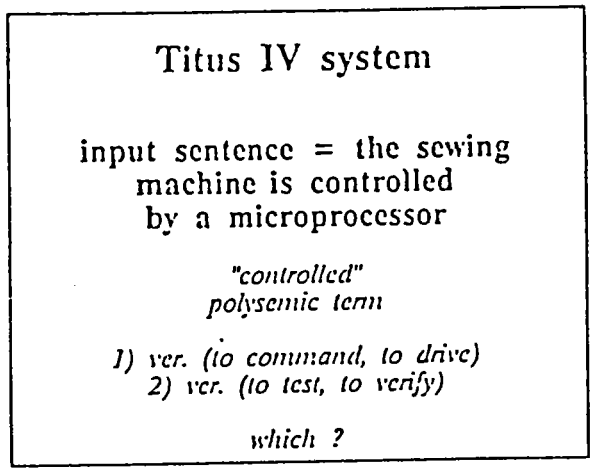

Il faut mentionner l'utilisation de signes diacritiques qui aident le système à différencier des formes homographes lorsqu'elles sont en majuscule (A => a ou à), et l'emploi de virgules pour reconnaître facilement l'antécédent d'un pronom relatif, d'un adjectif...

En résumé, le système a ses contraintes avec l'obligation pour l'opérateur de se plier à une certaine discipline et l'impossibilité de faire appel à un néophyte ignorant le domaine et donc incapable de donner suite aux requêtes du système. En contrepartie, la rigueur de la syntaxe assure la clarté du texte.

Evaluation

Le respect de la syntaxe contrôlée rallonge le temps d'entrée de 10% pour un résumé de 10 phrases.
Un opérateur qui maîtrise bien le système rentre 25 documents complets en 6 heures.

Le contrôle de la syntaxe et du lexique d'un document, l'affichage des messages d'erreur, la transformation des phrases en langage pivot, l'enregistrement des données binaires et les corrections effectuées a posteriori nécessitent 2,5 secondes de temps calcul sur un IBM 4331-2, en temps partagé et sous le système VM. Pour la recherche d'un document, sa traduction dans une des quatre langues et son édition, il ne faut qu'une seconde.

Exemples de traductions :

les exemples de traduction sont extraits du document cité en note.

---

(1) extrait de J. M. DUCROT : "Le système TITUS IV. Système de traduction automatique et simultanée en quatre langues" in : *Traduction Assistée par Ordinateur. Perspectives technologiques, industrielles et économiques envisageables à l'horizon 1990* (Actes du séminaire international - Paris - mars 1988), DAICADIF-Observatoire des industries de la langue, Paris, 1989, p. 62

DATE 12/05/82

TITUS 4 SYSTEM

FILE NAME : DEMO

SENTENCE NR : 02

INPUT LANGUAGE (DE,EN, ES, FR) = FR

INPUT SENTENCE

Les progrès récents des logiciels appropriés au traitement on-line des systèmes d'information ont favorisé le développement des bases de données dans tous les domaines des sciences et des techniques.

FRANCAIS

Les progrès récents des logiciels appropriés au traitement on-line des systèmes d'information ont favorisé le developpement des bases de données dans tous les domaines des sciences et des techniques.

ENGLISH

The recent progress of the software suitable for the on-line treatement of information systems has favored the development of data bases in all the fields of sciences and techniques.

DEUTSCH

Die neuen Fortschritte der fuer die on-line verarbeitung der informationssysteme geeigneten software haben die entwicklung der databasen in allen bereichen der wissenschaft und der techniken beguenstigt.

ESPAGNOL

Los progresos recientes del software apropriado para el tratamiendo on-line de los sistemas de documentacion favorecieron el desarrollo de las bases de datos en todos los campos de las ciencias y de las tecnicas.

next step command =

phrase d'entrée en français :

L'analyse du fluage des fibres de polyéthilène après irridiation sous vide montre ; qu'un processus de pontage survient dans la région amorphe ; tandis qu'une coupure de la chaîne moléculaire de la région cristalline est observée.

traduction en français :

L'analyse du fluage des fibres de polyéthilène après irridiation sous vide montre que un processus de pontage survient dans la région amorphe tandis que une coupure de la chaîne moléculaire de la région cristalline est observée.

traduction en anglais :

The polyethylene fiber creep analysis after irridiation under vacuum shows that a cross-linking process occurs in the amorphous region whereas a molecular chain scission of crystalline region is observed.

traduction en allemand :

WDie Analyse des Kriechens der Polyethylen-fasern nach der Bestrahlung unter Vakuum zeigt, dass ein Quervernetzungsprozess im amorphen Bereich auftritt, wogegen eine Molekulkettenspaltung des kristallinen Bereichs beobachtet wird.

traduction en espagnol

El analisis de la fluencia de las fibras de polietileno despues de la irridiacion debajo vacio muestra que un proceso de enlace transversal ocurre en la region amorfa mientras que una escision de la cadena molecular de la region cristalina es observada.

phrase d'entrée en français :

L'utilisation des systèmes de CAO dans l'industrie peut conduire à une réduction importante, des coûts de production ; si ces systèmes sont intégrés dans les lignes de fabrication.

traduction en français :

L'utilisation des sytèmes de CAO dans l'industrie peut conduire à une réduction importante des coûts de production si ces systèmes sont intégrés dans les lignes de fabrication.

traduction en anglais :

The use of CAD systems in industry can lead to a great reduction in production costs if these systems are integrated in production lines.

traduction en allemand :

Die Verwendung der CAD-Systeme in der Industrie kann zu einer grossen Produktionskostenreduzierung fuhren, wenn diese Systeme in den Fertigungstrassen integriert werden.

traduction en espagnol :

La utilizacion de los sistemas de CAO en la industria puede conducir a una reduccion importante de los costos de produccion si estos son integrados en las lineas de fabricacion.

phrase d'entrée en allemand :

Die analyse des Kriechens der Polyethylenfasern nach Bestrahlung unter Vakuum zeigt; dass ein Quervernetzungprozess in amorphen Bereich auftritt; wogegen eine Molekulkettenspaltung im kristallinen Bereich beobachtet wird.

traduction en français :

L'analyse du fluage des fibres de polyétilène après l'irridiation sous vide montre que un processus de pontage survient dans la région amorphe tandis que une coupure de la chaîne moléculaire est observée dans la région cristalline.

traduction en anglais :

Polyethylene fiber creep analysis after irridiation under vacuum shows that a cross-linking process occurs in the amorphous region whereas a molecular chain scission is observed in the crystalline region

traduction en allemand :

Die Analyse des Kriechens der Polyethylenfasern nach der Bestrahlung unter Vakuum zeigt ; dass ein Quervernetzungprozess im amorphen Bereich auftritt, wogegen eine Molekulkettenspaltung im Kristallinen Bereich beobachtet wird.

traduction en espagnol :

El analisis de la fluencia de las fibras de polietileno despues de la irridacion debajo vacio muestra que un proceso de enlace transversal ocurre en la region amorfa mientras que una escision de la cadena molecular es observada en la region cristalina.

phrase d'entrée en anglais :

An increase :in flexual strengh, and shear resistance :by 40 pc, and 25 pc is observed ; when aramid fibers are used in composite materials for automotive industry.

traduction en français :

Une augmentation de la résistance à la flexion et de la résistance au cisaillement de 40 % et de 25 % est observée quand des fibres aramides sont utilisées dans les matériaux composites pour l'industrie automobile.

traduction en anglais :

An increase in flexural strength and shear resistance by 40 % and 25 % is observed when aramid fibers are used in composite materials for automotive industry.

traduction en allemand :

Eine Erhöhung der Biegefestigkeit und des Scherwiderstandes um 40 % und 25 % wird beobachtet, wenn Aramidfasern in den Verbundwerkstoffen fur die Automobilindustrie verwendet werden.

traduction en espagnol :

Un incremento de la resistencia a la flexion y de la resistancia al cizallamiento de 40 % y de 25 % es observado cuando fibras aramida son utilizadas en los materiales compuestos para la industria del automovil.

phrase d'entrée en espagnol :

La naturaleza compleja de los productos formados por esta resina no permite de determinar ; si una correlacion estrecha existe : entre la liberacion de formaldehido, y la estructura quimica de los residuos y de los reactivos.

traduction en français :

La nature complexe des produits formés par cette résine ne permet pas de déterminer si une corrélation étroite existe entre la libération de formaldéhyde et la stricture chimique des résidus et des réactifs.

traduction en anglais :

The complex nature of products formed by this resin does not permit to determine if a close correlation exists between the formaldehyde release and chemical structure of residues and reactants.

traduction en allemand :

Die Komplexe Natur der durch dieses Harz gebildeten Produkte erlaub nicht zu bestimmen, wenn eine enge Korrelation zwischen dem Friesetzen von Formaldehyd und der chemischen Striktur der Ruckstande und der Reaktanten existiert.

traduction en espagnol :

La naturaleza compleja de los productos formados por esta resina no permite determinar si una correlacion estrecha existe entre la liberacion de formaldehido y la estructura quimica de los residuos y de los reactivos

2.3.3.3.11 TITUS V

Les performances de TITUS IV ont suscité l'intérêt de nombreux organismes. Il a été décidé de construire une version plus complète pour en élargir le cadre d'utilisation. Des études préliminaires ont permis de jeter les bases d'une conception qui s'inspire d'une nouvelle méthode d'analyse, qui tient compte des progrès techniques de l'informatique et de l'apparition de nouveaux outils issus de l'Intelligence Artificielle.

Parmi les caractéristiques du nouveau système :
- Construction d'un ensemble modulaire qui facilite l'ajout ultérieur de termes, de règles et de langues.

- Possibilité de stocker en langage pivot, à côté des éléments lexicaux de base et de leurs paramètres syntaxiques, des idées inférées ou même sous-jacentes dans certains cas. Il s'agit là d'une tentative d'analyse en profondeur... Le nouveau langage pivot devrait être indépendant des langues traitées. Les modules de génération du langage pivot seront écrits en PROLOG puis en langage C pour en garantir la portabilité, tout comme pour le logiciel de base.

- Assouplissement des règles de syntaxe contrôlée et accroissement du nombre des structures autorisées.

- Le langues traitées ne seront plus limitées aux quatre langues de TITUS IV. Les travaux préliminaires ont montré qu'il serait possible d'introduire sans grandes difficultés le portugais, l'italien et le roumain. Des recherches plus longues en ce qui concerne les grammaires sont envisagées, dans l'optique de traiter l'arabe littéraire, le chinois, le japonais et le russe. Les lexiques seront adaptés aux nouvelles techniques d'analyse et de transformation ainsi qu'aux nouveaux paramètres lexicaux.

- Les phrases ne seront plus limitées à une proposition. Seront acceptées : les indépendantes ou nominales (sans verbe), les principales, les subordonnées (de condition, temps, cause, conséquence, etc...), les relatives (même incluses), les complétives, les interrogatives (directes ou négatives indirectes, pseudo-négatives), les impératives et déclaratives, les formules idiomatiques.

- Si TITUS IV n'accepte que deux personnes, TITUS V acceptera toutes les formes verbales.

- L'entrée du texte sera facilitée par un traitement de texte souple et adapté aux langues étrangères traitées.

- La mise en forme et la sortie s'effectueront dans un environnement monolingue ou multilingue, avec un logiciel de P.A.O. (Publication Assistée par Ordinateur) et sur imprimante Laser.

2.3.3.4 Aides à la traduction

Il est difficile d'opérer des distinctions, parmi les systèmes qui traduisent automatiquement : certains nécessitent une intervention manuelle importante, d'autres laissent à l'homme le soin d'effectuer le travail essentiel de traduction, la machine n'intervenant que pour l'aider.

---

(1) J.-M. DUCROT : "Le projet TITUS V de traduction automatique" in *TAO*, Observatoire des industries de la langue, Actes du séminaire international (Paris, mars 1988), pp. 69-76

2.3.3.4.1 ALPS (Automated Language Processing Systems Ltd.)[1,2,3]

Comme WEIDNER (2.3.3.2.11), ALPS a bénéficié des travaux en informatique et en linguistique automatique effectués depuis les années 70 à l'Institut des Sciences de la Traduction (Brigham Young University à Provo dans l'Utah). En 1980, un groupe de chercheurs quitte l'institut et créent un centre de recherche pour développer des logiciels de traduction.. Le centre teste l'impact de ses produits sur le marché et concentre ses efforts sur leur convivialité. En 1983, le produit est commercialisé. En 1984, ALPS s'implante en Europe (Neuchâtel). En 1990, IBM, Sperry, Texas Instruments, l'Ecole polytechnique de Coventry, Unisys, NCR France, Norsk Data, l'Union des Banques Suisses, Rank Xerox, l'OTAN et Lexitel comptent parmi ses clients.
Indépendamment de son propre service de traduction, ALPS propose un large éventail d'outils informatisés, plus ou moins automatisés pour assurer une certaine souplesse d'emploi dans le sens où l'intervention de l'ordinateur devient modulable, où on l'adapte au type de texte et aux situations de traduction.
Le système fonctionne à plusieurs niveaux, chaque niveau englobant les niveaux inférieurs. Le niveau le plus élevé correspond au module de traduction automatique et fonctionne de façon interactive (phrase après phrase, il propose une traduction à l'opérateur après lui avoir posé des questions pour lever les ambiguïtés). Les modules principaux, SELECTERM, AUTOTERM et TRANSACTIVE, traitent les couples anglais-français, anglais-allemand, anglais-espagnol, anglais-italien, français-anglais et allemand-anglais.
ALPS propose un ensemble de logiciels, le TRANSLATION SUPPORT SYSTEM, qui doit aider le traducteur dans toutes les phases du processus de traduction : entrée, édition et analyse du texte source, création et édition de dictionnaires, traduction du texte source, édition, impression et transmission des documents traduits. L'ensemble des fonctions est accessible par menus. Des fenêtres d'aide en facilitent l'utilisation.
L'éditeur (TRANSLATION EDITOR) affiche les textes sources et cibles, page par page, avec une fenêtre au bas de l'écran pour visualiser les références lexicales. Il est possible de faire défiler les deux textes en parallèle. L'éditeur segmente automatiquement le texte source en unités de traduction, assure la consultation de dictionnaires on-line et affiche dans la fenêtre de référence lexicale l'expression équivalente dans la langue demandée. Il met à disposition des fonctions avancées de traitement de texte et réinsère dans le texte cible les codes de formatage (mise en page et typographie) du texte source. Il est également capable de stocker des passages à retranscrire sans modification dans le document de sortie.
- AUTOTERM recherche automatiquement les équivalences d'un terme source dans les dictionnaires on-line et les affiche. Il effectue une analyse du texte au niveau lexical et reconstitue la forme canonique des termes fléchis. Il indexe les équivalents affichés dans la fenêtre de référence et les incorpore directement dans le texte cible.
- REPETITION PROCESSING facilite la traduction de chaînes apparaissant plusieurs fois dans un même texte. Le remplacement est automatique mais peut être interrompu à tout moment.
Le traitement de texte multilingue (MULTILINGUAL WORD PROCESSING) comprend 400 caractères (lettres, chiffres, accents, signes de ponctuation, symboles, caractères spéciaux) qui peuvent être affichés à l'écran ou imprimés. Les claviers sont disponibles dans les différentes langues et respectent les dispositions normalisées des touches. Il répond aux besoin du traitement de textes classique et aux besoins de la traduction (consultation de dictionnaires on-line).

---

(1) Notice fournie par le siège européen de ALPS S.A. (3, avenue Beauregard, 2035 Corcelles, Suisse)
(2) Présentation du produit dans *Language Monthly*, the international journal for language and translation, n°20, may 1985
(3) A. DANIK : "The ALPS Computer Assisted Translation System", BCS Natural Language Translation Specialist Group Newsletter 14, 1984, pp. 5-14

Pour analyser le texte source et identifier les termes à entrer dans les dictionnaires de traduction, plusieurs outils sont proposés :
- TERMLOCATOR analyse les textes et identifie les mots et les phrases qui apparaissent plusieurs fois. Il crée un fichier des termes et un fichier de référence pour l'établissement des listes de fréquence (FREQUENCY LISTER) et de contexte pour une ligne ou pour une phrase (CONTEXT LISTER).
- La liste des mots non trouvés (WORDS-NOT FOUND LISTER) rassemble les mots qui n'ont pas été trouvés dans les dictionnaires. Ils pourront y être intégrés ultérieurement avec leurs traductions.

Les dictionnaires ont un format simple avec, pour chaque entrée, sa catégorie et ses traductions. L'éditeur (DICTIONARY EDITOR) permet d'en éditer le contenu. DIXTRACTION examine un texte avec plusieurs dictionnaires et produit un lexique spécifique après une analyse morphologique et syntaxique qui permet d'isoler les formes canoniques. Il recherche les formes de bases, classe les équivalents selon les priorités définies par l'utilisateur et supprime automatiquement les données dupliquées dans plusieurs dictionnaires. DICTIONARY/LOADING/UNLOADING convertit des fichiers de texte en dictionnaires. Des glossaires et des listes de mots émanant d'autres systèmes peuvent être convertis rapidement en données compatibles avec le TRANSLATION SUPPORT SYSTEM. La fonction inverse est également possible. DICTIONARY MERGING fusionne plusieurs dictionnaires on-line en un seul, l'intérêt consistant à construire un dictionnaire principal à partir de nombreux documents traitant un domaine identique.

A côté de ces outils, un ensemble de modules gère le fonctionnement du système :
- AERA MANAGEMENT organise et supervise des zones dans lesquelles sont stockés les textes, les dictionnaires et les traductions. Un menu permet à l'utilisateur de passer d'une zone à une autre, d'enregistrer dans une zone, de renommer une autre zone ou encore de lui assigner une langue de traitement.

- PRINTER QUEUE MANAGEMENT contrôle la file d'attente des textes à imprimer et prévoit tout type d'intervention.
- FORMATTING DISKETTES remplace avantageusement l'utilitaire du système UNIX.
- ARCHIVING/RETRIEVING se substitue aux fonctions backup et restore.
- IMPORTING/EXPORTING est un traducteur de format qui assure les transferts vers un autre système et l'importation de fichiers incompatibles.
- SENDING/RECEIVING est un support de communication qui utilise une sortie RS 232 en asynchrone.

Le système tourne sous XENIX (version Microsoft d'UNIX) sur un IBM AT, avec 2 Mo de mémoire centrale, un disque dur de 220 Mo (40 ms de temps d'accès), un moniteur monochrome EGA et une imprimante HP Laser.

Nous ne disposons pas d'exemples de traductions et n'avons pas eu l'occasion de tester le système. Une analyse du produits[1] révèle que lors d'un test chez Hewlett Packard à Guadalajara au Mexique, et sur un texte de 20 000 mots, les traducteurs sont passés de 200 à 567 mots traduits dans l'heure, (1321 mots pour le meilleur résultat, 465 pouir le plus mauvais). Un autre test, effectué au Canada[2], évalue à 30 000 mots la taille minimale du texte pour un gain d'efficacité de 15%.

---

(1) "Positive reactions from ALPS customers" in : *Language Monthly*, The international journal for language and translation, n° 20, mai 1985, Praetorius Limited, Nottingham, réimpression
(2) S. O'BRIEN : Customer Support Manager pour TSS (Translation Support System) chez Multiscript-La Langagerie à Montréal.

2.3.3.4.2 MERCURY

Commercialisé par LinguaTech aux Etats-Unis et par InfoARBED en Europe sous le nom de TERMEX, le produit doit être considéré comme l'élément d'une station de traduction. Il met à disposition un dictionnaire multilingue (anglais, français, allemand et néerlandais) et assure l'accès à des banques de données terminologiques par télécommunication[1].

2.3.3.4.3 MULTI LINGUA[2]

Le concept recouvre trois produits :

- TERMEX Dictionary Manager est intégré au programme de traitement de texte, il compile et édite la terminologie multilingue et permet d'accéder à une banque de données terminologiques multilingue.
- HARRAP'S CD-ROM propose une base de données et un dictionnaire multilingue (accès à une bibliothèque des plus grands dictionnaires bilingues).
- LINGUAWRITE compile des lettres d'affaires en cinq langues à partir d'une base de 10 000 phrases standard.

2.3.3.4.4 SITE (Sonovision ITEP Technologies)[2]

Le centre a développé deux outils d'aide à la traduction :

- PHENIX : un système de gestion de la terminologie.
- AQUILA : un ensemble de logiciels pour traducteurs professionnels et indépendants.

2.3.3.4.5 SMART[3]

SMART Communications Inc., implantée à New York, commercialise un système de traduction depuis 1972 en Amérique du Nord. Le produit n'est pas vendu en Europe. Le système est capable, semble-t-il, de livrer une traduction brute de 200 000 mots en une heure, sur un gros calculateur.
Il est utilisé par le Ministère du travail et de l'immigration à Ottawa pour traduire des descriptions d'emploi, de l'anglais vers le français. Il peut les afficher dans les minutes qui suivent sur 3500 terminaux répartis sur tout le Canada. La traduction est générée sur l'écran et révisée par l'opérateur. Si la qualité de la prestation est moyenne, il n'en reste pas moins vrai que le système est très rapide.
Il est composé de deux modules, MAX (SMART Expert Editor) et ST (SMART Translator). MAX analyse le texte et le réécrit sous une forme particulière, propre à faciliter le processus de traduction (insertions de marques grammaticales et lexicales).

Le produit est utilisé par plus de 30 grandes sociétés, comme General Electric USA. Les versions sont disponibles pour les couples anglais-français, anglais-espagnol, anglais-portugais, anglais-italien, ceci dans les deux sens. Des versions anglais-allemand, anglais-japonais, anglais-grec sont en préparation.

---

(1) W. J. HUTCHINS : "Recent Developments in Machine Translation. A review of the Last Five Years", in : *New Directions in Machine Translation*, Conference Proceedings, Budapest, 18-19 août 1988, pp. 21-22
(2) S. MELI : "Informationsmarkt der maschinellen Übersetzung" in *Terminologie et Traduction*, Commission des Communautés Européennes, n°3, 1989, pp. 90-91
(3) G. KINGSCOTT : *Applications of Machine Translation*, Study for the Commission of the European Communities, pp. 28-30

2.3.3.4.6 TII (Telecommunications Industries Inc.)[1]

La société commercialise le système TWP/70 (Translating Word Processor) pour des micro-ordinateurs compatibles IBM PC. Cet outil d'aide à la traduction est interactif et fonctionne sur les couples anglais-espagnol, anglais-russe, anglais-français, et ceci dans les deux sens. En prévision, les couples anglais-italien, anglais-allemand et anglais-portugais, dans les deux sens.

2.3.4 Prototypes en voie d'achèvement

2.3.4.1 ATAMIRA[1]

Développé en Bolivie, le système est multilingual et utilise une langue naturelle, l'aymara, comme langage pivot. Cette langue naturelle est particulièrement régulière dans sa morphologie et sa syntaxe. Il devrait fonctionner de façon interactive sur l'anglais, l'espagnol et l'allemand. Un bureau de traduction de Panama utilise déjà la version anglais-espagnol.

2.3.4.2 IBM Japon[1]

La société IBM Japon a construit un système anglais-japonais pour traduire ses propres manuels d'informatique. Il s'agit d'un système à transfert qui réalise d'excellentes traductions, pour ce qui concerne le domaine évoqué plus haut, tout au moins.

2.3.4.3 MELTRAN[1]

Mis au point par Mitsubishi, MELTRAN est un système interactif pour le couple japonais-anglais. Système à transfert, il nécessite une pré-edition et une post-édition, travaille en automatique ou par étapes. Le dictionnaire contient 50 000 entrées et 30 000 mots techniques. Ecrit en ESP, il traduit 5 000 mots à l'heure sur un MELCOM PSI, dans un environnement SIMPOS. Il est pratiquement commercialisable.

2.3.3.4 RMT (Ricoh Machine Translation)[1]

C'est un système de transfert de structures pour le couple anglais-japonais. Il est bâti sur les *Augmented CFG Dependency Trees.* Le dictionnaire de base contient 30 000 entrées, le dictionnaire utilisateur 30 000 et la terminologie 50 000 entrées. Il est écrit en langage C et tourne sur un 3B2 (AT&T-CPU) dans un environnement UNIX V. Il est capable de traduire 4 500 mots à l'heure. Une version japonais-anglais est en développement. Il est probablement commercialisé au moment où ces lignes sont écrites.

2.3.3.5 SHARP[1]

OA-110WB est un système interactif, à tranfert, et concerne le couple anglais-japonais . Il nécessite une étape de pré-édition et de post-édition. Le dictionnaire de base contient 60 000 entrées et 40 000 mots techniques. Il traduit des textes d'économie, de traitement de l'information, d'électronique et de constructions mécaniques, à la vitesse de 5 000 mots à l'heure. Il est écrit en langage C et tourne sur des ordinateurs Sharp (OA-110WS, OA-210, OA-310 et IX-7) dans un environnement UNIX V.

---

(2) S. MELI : "Informationsmarkt der maschinellen Übersetzung" in *Terminologie et Traduction*, Commission des Communautés Européennes, n°3, 1989, pp. 90-91

2.3.3.6 TOVNA

Présenté lors de la Conférence *"Translating and the Computer"* à Londres, en 1987, le système a été développé par D. COHEN, en Israël, puis à Londres. Les travaux ont démarré en 1970 et n'ont débouché sur une application commerciale qu'en 1985. La première version concerne le couple anglais-français. Les couples français-anglais et anglais-russe doivent être disponibles actuellement. le couple anglais-espagnol est prévu. Un système pilote est installé à la *World Bank* à Washington. Sa capacité d'apprentissage le distingue des autres systèmes. Il serait capable de mémoriser les corrections apportées par le traducteur pour en tenir compte ultérieurement. Son concepteur a annoncé[1] en août 1989 que la société Lexi-Tech à Moncton au Canada avait décidé de le substituer au système LOGOS. A l'origine de cette société, un contrat de 21 millions de dollars canadiens, et un volume de 100 000 pages de manuels techniques à traduire et à publier pour le ministère de la Défense. Avec un dictionnaire de 75 000 termes et expressions et un logiciel capable de faire l'interface entre le système de traduction et le système de publication assistée par ordinateur, Lexi-Tech compte faire de Moncton un centre international de traduction et d'édition.

2.3.3.7 TRANSTAR-1

Le projet a été conduit par la *Military Academy of Sciences*. Développé sur le couple anglais-chinois, il s'agit d'un système à transfert, automatique, nécessitant une étape de pré-edition (réduite) et de post-édition. TRANSTAR-1 inclut des programmes de compilation de lexiques anglais-chinois et des utilitaires d'analyse statistique de textes en anglais. Les domaines traités sont les recherches militaires, l'électronique, la chimie et les sciences économiques.

2.3.5 Projets

L'énumération de ces projets, bien que partielle, nous donne un aperçu de la situation actuelle et des tendances, dégage des nouvelles orientations de la recherche et du développement.

2.3.5.1 ATTP (Automatic Translation Typing Phone)

Ce prototype imaginé par Toshiba (Japon) introduit une nouvelle composante : la communication par satellite. La liaison s'effectue entre deux partenaires en anglais ou en japonais. Le texte anglais est transmis à une station de travail Toshiba-3000 qui le traduit en japonais grâce à un logiciel résident. La traduction est envoyée au correspondant par satellite. La réponse est rédigée en japonais sur une station de même type, traduite en anglais et expédiée par satellite. Les textes s'affichent de part et d'autre, sur des écrans partagés.

2.3.5.2 BRITISH TELECOM

Les recherches lancées en 1984 par British Telecom ont pour objectif de réaliser un système de traduction automatique des communications téléphoniques d'affaire, opérationnel et commercialisable en 1995.
L'interlocuteur parle lentement et distinctement dans un micro relié à un micro-ordinateur Merlin 2000. La communication est validée, traduite et générée par un programme

---

(1) au cours du *Machine Translation Summit II* à Munich, en août 1989.

de synthèse de la parole. Les langues à l'étude sont l'anglais, le français, l'allemand, l'italien, l'espagnol et le suédois. Le corpus contient 400 expressions courantes.
Aux difficultés habituelles de la traduction automatique s'ajoutent ici les problèmes de reconnaissance de la parole. KEY (Key Technology Centre) travaille sur un projet similaire au Japon.

2.3.5.3 BYU-TAS[1]

L'équipe de la Brigham Young University (USA) développe une station de travail pour traducteur. Elle devra rassembler un traitement de texte, une gestion de fichiers terminologiques personnels, communiquer avec d'autres stations, pouvoir interroger des bases de données extérieures et se connecter à un système de traduction automatique. MELBY[2] propose un nouveau type de base de données composée de textes sources et de textes cibles manipulés avec des routines de recherche de chaînes de caractères. L'introduction des termes dans la base et leur traduction en sont considérablement simplifiées.

2.3.5.4 CAP SOGETI[1]

Comme le GETA de Grenoble, la société Cap SOGETI Innovations a orienté ses travaux vers la réalisation d'une station de traduction ("Translator's workstation language engineering workshop") qui doit offrir des outils "intelligents", un traitement de texte multilingual, une base de connaissances de la langue naturelle et un analyseur.

2.3.5.5 DLT (Distributed Language Translation)[3]

Ce projet de recherche et de développement à long terme est une initiative de BSO/Research à Utrecht (Pays Bas). Il a démarré en 1982 par une étude de faisabilité financée par la Communauté Européenne. Financé depuis 1984 à 50% par le ministère des Affaires Economiques et à 50% par BSO, il bénéficie d'un budget annuel d'1 million de dollars, 5 millions de dollars pour les années 1988-1991. La commercialisation n'est pas envisagée avant 1992.
Les caractéristiques essentielles du système sont les suivantes :

- Architecture à langue-pivot[4] : DLT a retenu l'esperanto comme langage pivot. Il s'agit d'une langue artificielle très formalisée qui se prête sans problèmes à l'application des grammaires de CHOMSKY et permet de désambiguïser les textes à un niveau sémantique.
- Ouverture plurilingue : A cet égard, le choix de l'esperanto ouvre des perspectives excellentes à long terme. Les racines de son vocabulaire sont d'origine européenne (langues romanes et langues germaniques), la structure de la phrase est slave, les mécanismes de formation des mots et l'invariance des morphèmes l'assimilent à une langue agglutinante. Les efforts de recherches se sont portés sur le couple anglais-français. Des travaux exploratoires ont été menés sur le finnois, le hongrois, le chinois et le japonais.

---

(1) S. MELI : "Informationsmarkt der maschinellen Übersetzung" in *Terminologie et Traduction*, Commission des Communautés Européennes, n°3, 1989, pp. 90-91
(2) A. MELBY : "Creating an Environnment for the Translator, in : M. KING (Ed.), *Machine Translation Today*, Edinburgh University Press, Edinburgh, 1987
(3) K. SCHUBERT : "Interlingual terminologies and compounds in the DLT project", in *Proceedings of the International Conference on Machine and Machine-Aided Translation*, Birmingham, April 1986
(4) T. WITKAM : "Interlingual Machine Translation - An Industrial Initiative" présenté au Machine Translation Summit, Hakone, Japon, septembre 1987

- Intelligence Artificielle : DLT inclut des techniques de raisonnement issues de l'Intelligence Artificielle (IA) pour réaliser une interprétation basée sur la com-préhension. Ces techniques[1] sont conçues pour exploiter au mieux l'architecture à langage pivot et assurer le potentiel d'extension du système.
- Saisie de texte en interactivité : Les concepteurs de DLT pensent, sans doute à juste titre, qu'en dépit des apports de l'Intelligence Artificielle, la traduction automatique de haute qualité n'est pas pour demain. La possibilité d'initier un dialogue entre la machine et l'auteur du texte est un moyen beaucoup plus simple et plus fiable d'utiliser l'intelligence. Au correcteur d'orthographe et au correcteur de style sont associés des outils performants capables d'interroger l'auteur du texte et de lui demander des précisions quant à l'interprétation d'un mot ou d'une phrase. Cette opération de désambiguïsation, lors de l'étape d'analyse ou de transfert, est en langue source. Un système d'apprentissage stocke les données recueillies dans la base de données SWESIL (Semantic Word Expert System for the Intermediate Language).
- Mise en réseau : DLT s'écarte de la configuration traditionnelle des grands systèmes de traduction automatique concentrés sur un gros calculateur. La traduction se déroule à l'émission et à la réception, au niveau des terminaux mis en réseau. Les données transitent entre les terminaux sous une forme intermédiaire (esperanto). Les terminaux disposent d'un exemplaire du système (sur CD-ROM ou équivalent), d'une banque de connaissances et des dictionnaires afférents à une langue spécifique. On ne partage pas le logiciel ou les capacités de stockage, on partage le langage pivot.

Le niveau de qualité attendu est élevé. Il n'y aura pas de post-editing.

3.3.5.6 EDR (Electronic Dictionary Research Institute)[2]

Alors qu'en 1981, le Japon avait lancé le projet ambitieux de l'ordinateur de 5ème génération[3], 1986 est l'année d'un gigantesque effort national en faveur de la traduction automatique qui avait déjà mobilisé, sans grands résultats et depuis 1950, les équipes universitaires de Kyoto et de Kyushu. Il faut cependant citer ATLAS (2.3.3.2.1) conçu par Fujitsu et disponible depuis 1984, PIVOT (2.3.3.2.7) de NEC, TAURUS de Toshiba et TRANSWORD PRO (2.3.3.2.8) de SANYO. Les insuffisances de ces systèmes de deuxième génération liées à la nature des modèles actuels d'analyse sémantique ont conduit les japonais à créer, en avril 1986, l'Electronic Dictionary Research Institute qui, un peu à la manière de l'ICOT (Institute for New Generation Computer Technology), va gérer un programme[4] de 9 ans et un crédit de 1,5 milliard de francs.

Le programme a été mis sur pieds par huit industriels (Fujitsu, Hitachi, Nec, Matsushita Electronic, Mitsubishi Electric, Oki Electric, Sharp et Toshiba) avec l'aide du JKTC (Japan Key Technology Center), agence gouvernementale pour la promotion de la recherche dans le secteur privé. Le dictionnaire électronique regroupera un dictionnaire maître de 200 000 mots japonais, de 200 000 mots anglais et de 100 000 termes techniques, ainsi qu'un dictionnaire composé de la description des concepts (description du sens de chaque mot du dictionnaire maître sous forme de "frames[5]") et de leur

---

(1) **B. C. PAPEGAAIJ** : "Word Expert Semantics : an Interlingual Knowledge Based Approach", in : V. SADLER, T. WITKAM (Eds.), Dordrecht/Riverton, Foris, 1986

(2) **M. NAGAO, J. TSUJII, J. NAKAMURA** : "The Japanese Government Project for Machine Translation" in Computational Linguistics, 11-(2-3), 1986, pp. 91-110

(3) Sciences et Techniques, n° 17, janvier 1985, p. 38

(4) **E. LAUNET** : "Traduction automatique : Effervescence japonaise" in Sciences et Techniques, n° 35, mars 1987, pp. 34-36

(5) Frame : ce terme désigne en Intelligence Artificielle, un type particulier de représentation des connaissances

classement sous forme de réseaux sémantiques. La gestion de cette énorme base de données fera également l'objet de recherches approfondies. Un réseau à commutation de paquets relie les postes de travail de l'institut et les huit laboratoires industriels. Le réseau est étendu progressivement aux organismes qui souhaitent participer à l'alimentation du dictionnaire (maisons d'édition, centres de recherche...). Un prototype est prévu pour fin 1991. Il tirera sans doute bénéfice de nouvelles architectures symboliques développées à l'ICOT et améliorera la qualité des systèmes de traduction actuels.

2.3.5.7 EUROTRA (EUROPEAN TRANSLATION SYSTEM)

Lancé par la Communauté Economique Européenne en novembre 1982, il s'agit du projet de Traduction Automatique le plus ambitieux et le plus important quant au personnel et au potentiel d'extension. L'objectif de ce programme de recherche et de développement est de construire le prototype préindustriel d'un système de T.A. de conception avancée, qui couvre les 9 langues (7 initialement) de la Communauté : allemand, anglais, danois, espagnol, français, grec, italien, néerlandais et portugais.
Des équipes universitaires des pays membres (242 personnes, dont 80 % de linguistes, traducteurs, informaticiens et mathématiciens, réparties sur 21 sites) travaillent pour leur langue respective, sur les modules d'analyse et de synthèse. Ils ont à charge également la réalisation du module de transfert vers leur langue. Le projet se déroule en trois phases. Après la détermination du modèle théorique et la conception du formalisme (1982-1984), les études linguistiques[1] (1985-1988) ont préparé l'élaboration d'une maquette de prototype qui devrait clore la phase 3 (1988-1990) et fonctionner avec un vocabulaire de 20 000 mots (dont 15 000 termes techniques du domaine des télécommunications).
Il s'agit d'un système multilingue[2] au sens global du terme, qui traite les 12 langues de la Communauté dans leur ensemble, avec une même approche linguistique. On utilise un modèle unique pour passer d'une langue à une des huit autres et on s'appuie sur une même description pour toutes les étapes de la traduction, que la langue soit source ou cible. Le système est organisé schématiquement en trois étapes : analyse, transfert et génération. L'analyse et la synthèse sont conçues dans un environnement monolingue. Il existe donc 9 modules d'analyse, 9 modules de génération et 72 modules de transfert. Pour que ce dernier soit le plus simple possible, il est indispensable d'éviter des modifications de structure pendant le transfert en analysant la syntaxe et la sémantique des unités de traduction (paragraphes, phrases,...) et en présentant les résultats sous une forme indépendante de la langue (ordre canonique des mots). Il est programmé en C-Prologue dans un style déclaratif basé sur les grammaires d'unification mais devrait être réécrit en langage C à un stade industriel.
L'hypothèse de base est que le processus de traduction est une succession de plusieurs transformations au cours desquelles un texte doit être retranscrit, de sa forme originale (texte source) jusqu'à la sortie correspondante (texte cible) sous des représentations grammaticales successives correspondant à des impératifs linguistiques (niveaux de la morphologie, de la syntaxe de surface, de la syntaxe profonde, de la sémantique). Chaque niveau de représentation est défini par une grammaire ("générateur") composée d'un ensemble de règles ("constructeurs"). L'application de ces règles produit des arbres décorés. Les objets d'un niveau de représentation sont transcrits dans le niveau suivant par un autre ensemble de règles ("translateurs").

---

(1) **EUROTRA** : *Reference Manual.* Final Version 5.0, non publié, 1988
(2) **L. DANLOS** : "Rapport préliminaire sur Eurotra-France", rapport à usage interne, février 1987
(3) **M. KING** : "EUROTRA : General System Description", ISSCO, Genève, novembre 1985, ETL-6 : Final report
(4) **H.-D. MAAS** : "The dictionary in the Eurotra Engineering Framework" in *Sprache und Datenverarbeitung*, 1/1987, Niemeyer, Tübingen, 1987, pp. 15-21

Examinons le système d'un peu plus près. Pour un couple de langues (langue source LS et langue cible LC), trois modules sont responsables du processus de traduction :
- le module d'**analyse** produit une représentation du texte LS
- le module de **transfert** transforme la représentation du texte LS en une représentation du texte LC
- le module de **génération** traduit la représentation du texte LC en un texte LC.

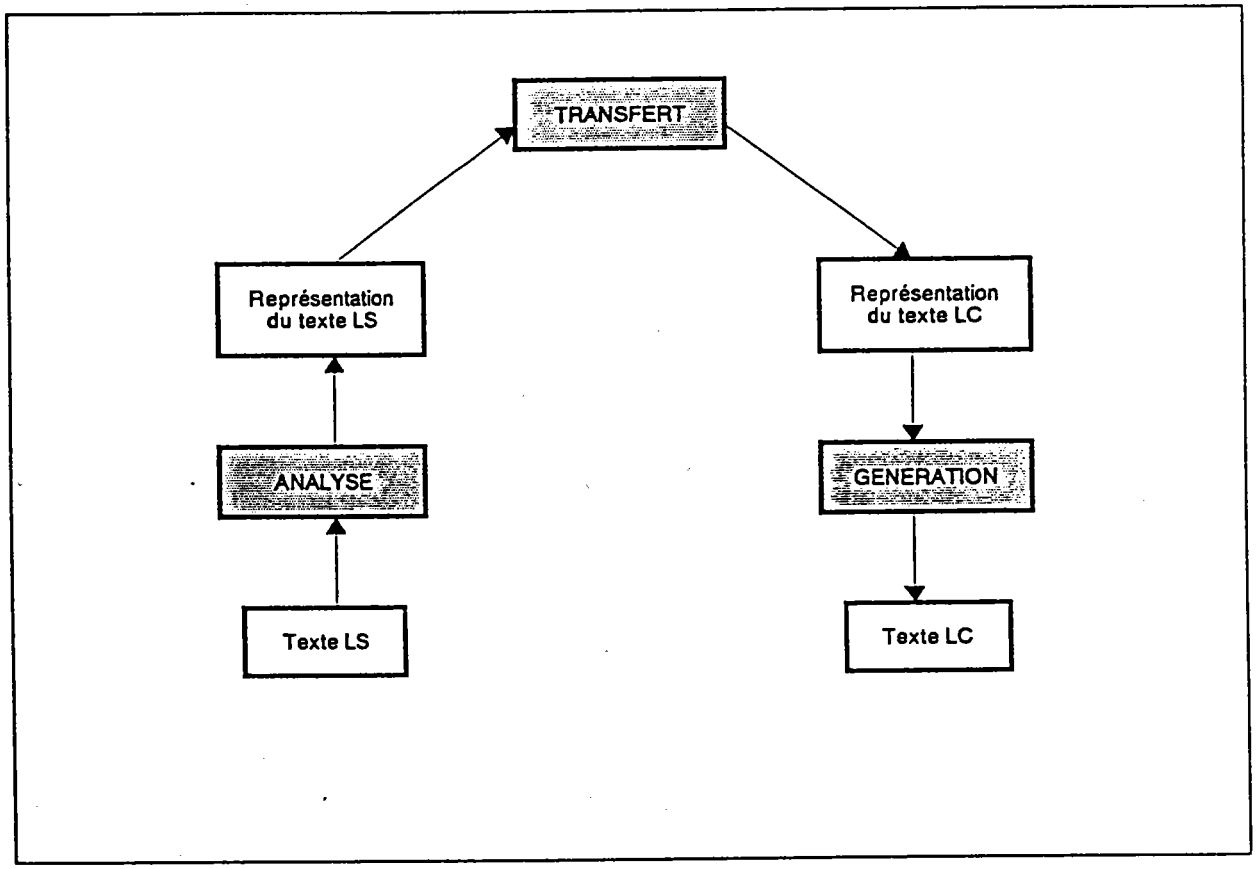

Pour 9 modules d'analyse et 9 modules de génération (ils sont construits pour chaque langue, dans une optique monolingue), nous avons 72 modules de transfert qui permettent de passer de la représentation du texte LS à la représentation du texte LC. Parce qu'ils sont nombreux, ces modules doivent être aussi simples que possible et par conséquent les représentations IS (structure d'interface) aussi proches que possible pour la langue source et la langue cible. La représentation IS décrit la phrase en termes de *prédicats*, d'*arguments* et de *modifieurs*. Elle prend la forme d'un arbre décoré dont les feuilles correspondent aux entrées lexicales des langues source ou cible. C'est au prix de cette abstraction que le système atteindra un niveau supérieur à ce que donnaient jusqu'ici des représentations essentiellement syntaxiques et que l'intégration ultérieure d'une ou plusieurs langues ne devrait pas poser de problèmes insurmontables.

Analyse

L'analyse s'effectue en trois étapes.

1. ECS (Eurotra Constituant Structure) : au cours de cette analyse syntaxique, les mots de la phrases sont étiquetés selon leur catégorie (V, N, Det, Adj. ...) et regroupés en GN (Groupe Nominal), GV (Groupe Verbal) ou GP (Groupe Prépositionnel).

Prenons la phrase *un employé a volé un gâteau au président.*

Le dictionnaire ECS[1] donne la catégorie et les traits flexionnels de chaque mot :

volé = verbe, participe passé, masculin singulier
président = nom, masculin singulier
président = verbe, 3ème personne du pluriel, présent, indicatif

La grammaire ECS dans une version simplifiée donnerait pour la catégorie "phrase" notée (P) :

P -> Advp* GN [nbre = n] GV [nbre = n]

GN [nbre = n] -> Dét [nbre = n] (Adj) [nbre = n] N [nbre = n]

GV [nbre = n] -> SGV [nbre = n] (GN) (GP) Advp*

GP ->Prép GN

Advp -> Adv

Advp -> GP

Un constituant entre parenthèses apparaît 0 ou 1 fois. Le signe * signifie qu'un constituant apparaît 0,1 ou plusieurs fois. Un élément entre [ ] est un couple attribut-valeur. La valeur est une constante ou une variable. Dans l'élément [nbre = n], n est une variable qui indique l'accord en nombre sujet-verbe et l'accord entre les constituants d'un groupe nominal.
L'analyse de la phrase donne les arbres non décorés suivants :

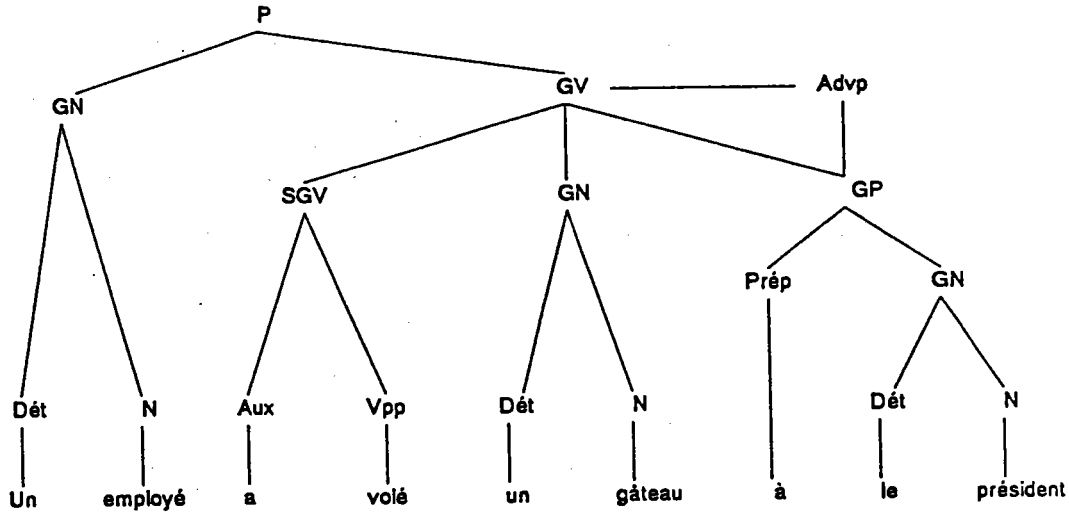

La grammaire évoquée donne deux résultats possibles :

- *au président* est complément de verbe, le noeud GP est un fils du noeud GV
- *au président* est un adverbial, le noeud GP est un fils du noeud Advp.

---

(1) Exemples extraits de L. DANLOS : "Le projet EUROTRA. Annexe technique" in : A. ABBOU : *Traduction Assistée par Ordinateur*, actes du séminaire international, Paris, mars 1988, pp. 79-86

Au niveau ECS, l'analyse de deux phrases formellement identiques donne le(s) même(s) résultat(s), sans que l'on tienne compte des feuilles de l'arbre. Soit la phrase *un employé a mangé un gâteau au lit.*. On obtiendra deux analyses identiques à celles de la phrase précédente *un employé a volé un gâteau au président.*

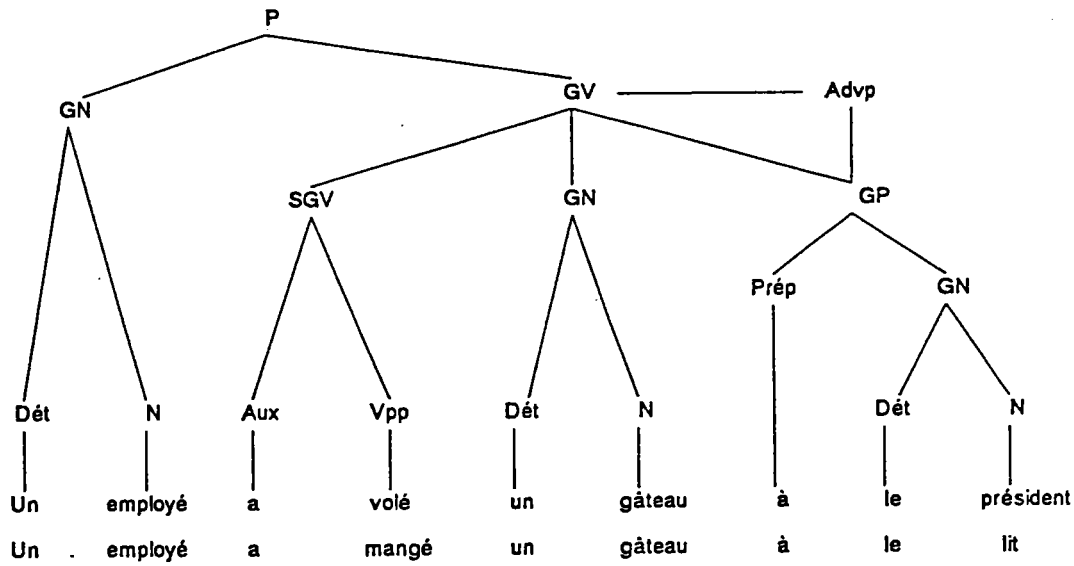

2. ERS (Eurotra Relational Structure) : l'analyse relationnelle réorganise les constituants ECS selon leur fonction syntaxique : verbe, sujet, objet-direct, modifieur...

Le dictionnaire ERS des verbes donne leur complémentation, à l'actif, pour chaque emploi :
- voler1 (*il a volé un jouet à son frère*) : se construit avec un objet-direct et un objet prépositionnel introduit par *à*. On représente ces indications en écrivant : [ers-frame = dir-obj_à-objet].
- voler2 (*le commerçant vole sa clientèle*) : se construit avec un objet direct. On écrira : [ers-frame = dir-objet].
- voler3 (*l'aigle vole vers son aire*) : se construit avec un objet locatif. On écrira : [ers-frame = loc-objet].
- manger se construit avec un objet direct : [ers-frame = dir-objet].

La grammaire ERS indique pour une phrase les compléments du verbe qui peuvent apparaître selon sa complémentation :

P -> verbe[ers-frame = dir-objet_à-objet] sujet dir-objet à-objet à-objet Modif*

P -> verbe[ers-frame = dir-objet] sujet dir-objet Modif*

Au cours du transfert ECS -> ERS, les informations lexicales du niveau ERS vont permettre d'éliminer l'analyse de *un employé a mangé un gâteau au lit* qui donne *au lit* comme groupe prépositionnel complément de verbe. En effet, *manger* n'accepte pas de à-objet.

Pour la phrase *un employé a volé un gâteau au président*, la grammaire ERS donne trois solutions, deux avec voler1 (*au président* à-objet ou modifieur car le à-objet de voler1 est codé comme facultatif), une avec voler2 (*un gateau* est objet-direct et *au président* modifieur.

On peut représenter d'une façon simplifiée le résultat de l'analyse pour voler1 avec *au président* comme à-objet.

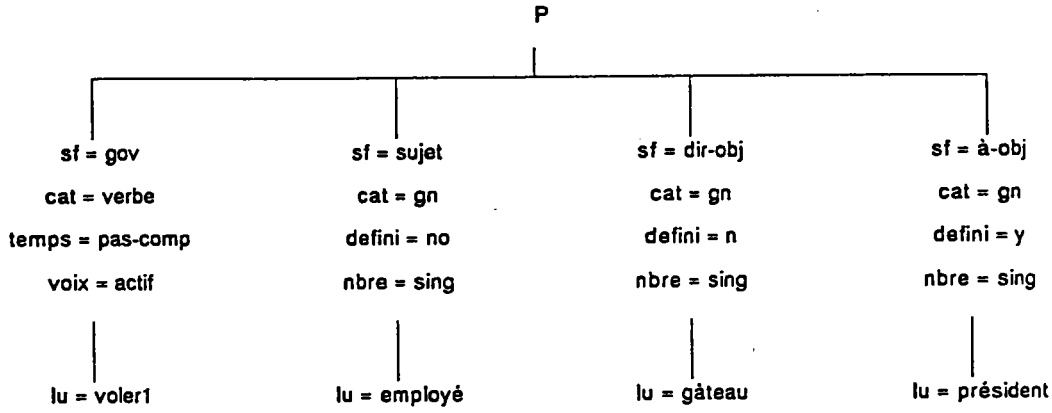

3. IS (Interface Structure) : l'analyse sémantique réorganise les fonctions ERS selon leur rôle sémantique : prédicat (Gov), argument (Argi) et modifieur (Modif).

Le dictionnaire IS indique la complémentation du verbe en termes d'argument ("is-frame") dont il spécifie les catégories distributionnelles.

- voler1 a 3 arguments, le premier (sujet) et le troisième (à-objet) sont humains. Cela s'ecrit : is-frame = arg123, hum-arg1 = y, hum-arg2 = n, hum-arg3 = y.

- voler2 a 2 arguments humains : is-frame = arg12, hum-arg1 = y, hum-arg2 = y.

Pour les noms, il indique leur catégories distributionnelles.

- employé est un humain : i.c. hum = y
- gâteau est non-humain : i.c. hum = no

La grammaire IS garantit pour une phrase qu'il y a compatibilité entre les catégories distributionnelles des compléments de verbe et ces compléments. Elle élimine l'analyse de *un employé a volé un gâteau au président* avec voler2 (2 arguments humains). La grammaire ne valide pas un groupe adverbial de la forme *à N* où *N* est humain. L'analyse avec voler1 où *au président* est adverbial est éliminée.

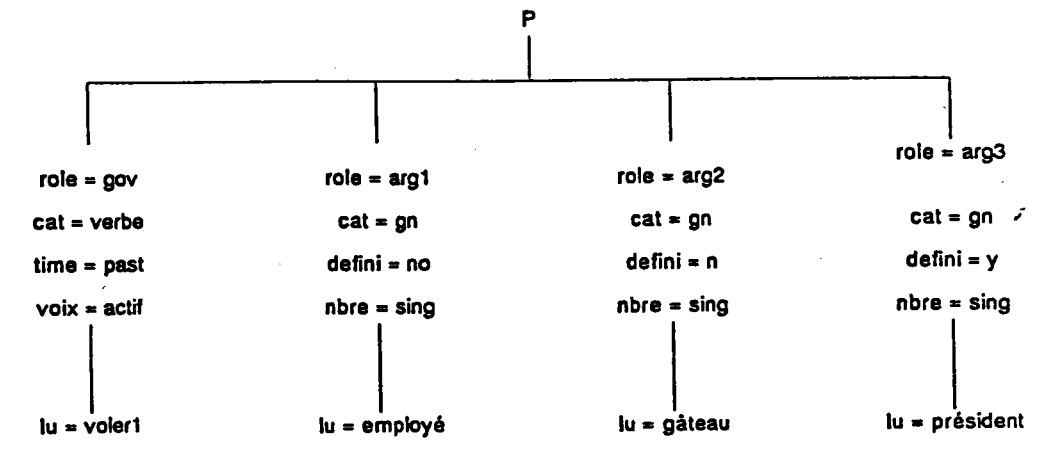

En résumé, à chaque niveau d'analyse correspond un dictionnaire et une grammaire. On obtient à chaque fois un arbre décoré, ou plusieurs s'il y a ambiguïté. Lorsque l'on passe d'un niveau à un autre, ECS -> ERS ou ERS -> IS par exemple, on effectue "un transfert" et on modifie l'arbre décoré.

Transfert IS -> IS[1]

Lorsque le transfert est simple, l'arbre IS de la langue source et l'arbre IS de la langue cible sont isomorphes. Les feuilles de l'arbre LC représentent la traduction des feuillles de l'arbre LS. Pour la phrase *un employé a volé un gâteau au président* nous obtiendrons un arbre anglais isomorphe, de sorte que le transfert IS -> se résumera à un transfert lexical.

(lu = voler1) -> (lu = steal1)
(lu = employé) -> (lu = employee)

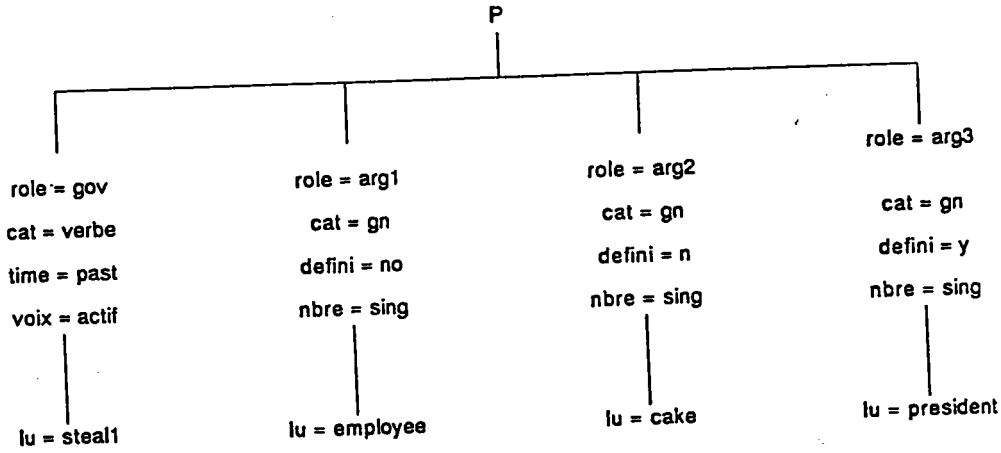

Comme les transferts précédents (ECS -> ERS et ERS -> IS) le transfert IS -> IS s'effectue de la même façon. La grammaire et le dictionnaire IS permettent d'éliminer les transferts lexicaux ou syntaxiques qui génèrent des ambiguïtés.
Le transfert peut être complexe lorsque les structures IS de la langue source et de la langue cible ne sont pas isomorphes (absence de correspondance lexicale, correspondance lexicale mais nombre différent d'arguments...).

Génération

On effectue les étapes de l'analyse en ordre inverse :
IS -> ERS -> ECS -> Texte source

Les dictionnaires et les grammaires de chaque niveau (ECS, ERS et IS), pour une langue donnée, sont utilisés pour l'analyse et la génération. Il n'y a qu'une différence entre l'analyse et la génération, au niveau des transferts :
Pour ECS -> ERS, en analyse, les compléments du verbe sont rangés dans l'ordre canonique de la phrase à l'actif.
Pour ERS -> ECS, en génération, l'ordre canonique des compléments est modifié.

---

(1) J. HALLER : "Anwendung linguistischer Forschungsergebnisse in der Maschinellen Übersetzung : Die Diskussion der Interface-Struktur (IS) in EUROTRA" in *Sprache und Datenverarbeitung*, SDv 1/1987, pp. 8-14

En résumé, nous dirons que quel que soit le niveau de représentation, on utilise un même formalisme pour les grammaires, les dictionnaires et les "transferts", un formalisme déclaratif basé sur les grammaires d'unification. On soulignera que les étapes d'analyse et de génération sont poussées au maximum pour réduire le transfert au minimum, c'est-à-dire à un transfert lexical. L'analyse doit déterminer les structures morpho-syntaxiques (syntaxe de surface) et les structures sémantaxiques[1] (relations de type grammatical, syntaxique, argumentaire, modal, aspectuel et temporel). L'interface obtenue à la fin de l'étape d'analyse conserve la structure sémantique et les indications lexicales, elle laisse les informations morphosyntaxiques devenues inutiles. La phase de génération s'appuie sur cette interface pour chercher les équivalents dans la langue cible, sans recours donc à la morphosyntaxe de la langue source. Il est malheureusement des situations dans lesquelles on ne peut pas être suffisamment abstrait au niveau de l'interface et où il faut alors recourir à des "stratégies de compensation".

2.3.3.8 GETA

En 1961, le CNRS crée le CETA (Centre d'Etudes pour la Traduction Automatique). De 1961 à 1971, le centre élabore de nombreux outils informatiques et les expérimente sur le couple russe-français. De nombreuses expériences sont conduites sur l'analyse de l'allemand et du japonais. En 1971, après de longs développements sur différents types de grammaire et de dictionnaire, un corpus de 400 000 mots est traduit du russe vers le français par un système de seconde génération[2] (analyse morphologique d'états finis, analyse syntaxique par grammaire augmentée indépendante du contexte, analyse sémantique procédurale vers un langage pivot, transfert lexical, génération syntaxique puis morphologique).
En 1972, apparaît le GETA[3] (Groupe d'Etudes pour la Traduction Automatique), qui est un laboratoire du Département d'Informatique de l'université de Grenoble. L'équipe s'oriente vers la mise au point de langages spécialisés pour la programmation linguistique et produit ARIANE, un environnement complet de programmation qui permet de construire des modèles linguistiques. Pour exploiter ses résultats, le GETA participe au PNTAO (Projet National de TAO) et à la construction du système CALLIOPE.

2.3.3.8.1 ARIANE[4,5]

La société B'VITAL, issue du GETA, propose deux types de produits :
- les linguiciels (définition et réalisation de dictionnaires automatiques, conception et développement de grammaires syntaxo-sémantiques, adaptation ou extension de systèmes de TAO)
- les logiciels (outils automatisés pour le codage des dictionnaires, réalisation d'environnements de traduction, conception et réalisation d'ateliers spécialisés pour la programmation linguistique, traitement de texte et de programmes dans un contexte multilingue, constructions de bases de données lexicales...).

---

(1) G. BOURQUIN : "Le programme EUROTRA : les aspects linguistiques" in *Traduction Assistée par Ordinateur*, sous la direction de A. ABBOU, Editions Daicadif, séminaire international de Paris, mars 1988, pp. 87-88

(2) C. BOITET, N. NEDOBEJKINE : "Recent Developments in Russian-French Machine Translation at Grenoble". in : *Linguistics 19*, 1981, pp. 199-271

(3) B. VAUQUOIS : *La Traduction Automatique à Grenoble*. Documents de Linguistique Quantitative, n° 29, Dunod, Paris, 1975

(4) M. QUEZEL-AMBRUNAZ : "ARIANE-78. Système interactif pour la traduction automatique multilingue", *Document GETA*, 1978

(5) J.-P. GUILBAUD : "Le modèle allemand-français comme exemple d'application du système ARIANE-78", *11th International ALLC Conference*, Nice, juin 1985

Parmi tous ces produits, elle commercialise ARIANE-78[1], logiciel de base pour la TAO, sous plusieurs versions :
- pour matériel IBM 43XX, 30XX, 93XX et compatibles
- avec maquette de traduction sur PC/AT 370

Le logiciel de base ARIANE-78 a été développé par le GETA. Il offre un environnement interactif et des métalangages spécialisés pour la programmation linguistique, dans le but de développer des systèmes de traduction. Les langages spécialisés permettent de rentrer des données, d'écrire des grammaires et des dictionnaires qui seront compilés et interprétés par des programmes adaptés. Le système créé est assimilable à un système expert avec la base de connaissances et le moteur d'inférence. C'est un système de deuxième génération, entièrement automa-tique, qui applique le processus de traduction en trois étapes : analyse, transfert, génération. Bien que né en 1978, il est de conception moderne et traite des structures de données sous forme d'arbres décorés. Chaque noeud de l'arbre comporte un registre (décoration) dans lequel sont stockées toutes les variables d'information fournies au système.

1. Analyse

L'analyse morphologique est écrite dans le langage ATEF et transforme le texte en un arbre décoré. Chaque mot est éventuellement découpé en radicaux (allemand) et reçoit d'un dictionnaire les informations qui lui correspondent.
L'analyse structurale est écrite dans le langage ROBRA[2] et transforme l'arbre plat en une structure intermédiaire source qui donne une interprétation complète de la phrase, sur quatre niveaux :

- classes morphosyntaxiques et syntagmatiques
- fonctions syntaxiques
- relations logiques
- relations sémantiques

Les règles de grammaire expriment les transformations qui seront appliquées localement dans l'arbre.

2. Transfert

Le transfert lexical transforme chaque noeud de l'arborescence source en une sous-arborescence cible après consultation d'un dictionnaire bilingue écrit dans le langage TRANSF. Il se poursuit au début du transfert structural tant que des tests sont nécessaires sur l'arborescence.

Le transfert structural transforme l'arbre intermédiaire source en arbre intermédiaire image en effectuant les opérations suivantes :

- désambiguïsation partielle de l'arborescence en cas de polysémies.
- traitement de l'article
- calcul des modes et des temps
- calcul de pondération pour péparer la mise en ordre syntaxique
- nettoyage et mise en forme de la structure

---

(1) C. BOITET, P. GUILLAUME, M. QUEZEL-AMBRUNAZ : "ARIANE-78 ; an Integrated Environment for Automated Translation and Human Revision". in : *Proceedings of COLING-82*, Prague, 1982

(2) C. BOITET, P. GUILLAUME, M. QUEZEL-AMBRUNAZ : "Manipulations d'arborescences et parallélisme : le système ROBRA". in : Proceedings of COLING-78, Bergen, 1978

3. Génération

La génération syntaxique génère les feuilles de l'énoncé cible et les ordonne en parcourant l'arborescence de haut en bas de façon récursive.
La génération morphologique est écrite dans le langage SYGMOR et utilise les résultats précédents.
L'analyse et la génération sont strictement monolingues. Seul le transfert est bilingue. Le fait que les étapes soient distinctes et qu'ARIANE puisse gérer l'aspect multilingue permet de concevoir des systèmes qui n'utilisent qu'une même analyse pour traduire vers plusieurs langue ou une même génération pour traduire à partir de plusieurs langue.
On constate que le GETA a abandonné le concept de langage pivot qu'il avait retenu pour le projet initial. Son système repose sur des langages spécialisés, (ATEF, ROBRA, TRANSF, SYGMOR). Langage de haut niveau, ROBRA est un transducteur d'arbres utilisé pour l'analyse structurale, le transfert structural et la génération syntaxique. Il utilise des données (variables et arbres décorés avec des opérateurs associés - comparaison, affectation, transformations par règles -) et des structures de contrôle (affectations conditionnelles de variables, application des règles en parallèle, non-déterminisme dans le graphe de contrôle). La caractéristique essentielle de ROBRA est sa récursivité qui permet au système, lorsqu'il emprunte une mauvaise voie dans le graphe de contrôle des sous-grammaires, de revenir en arrière et de tester une autre possibilité. Dans le cas d'une impasse, ARIANE peut interrompre la procédure à différents niveaux et produire des traductions "sous-optimales". La complexité se paye cher puisque la traduction d'un mot nécessite 1,5 million d'opérations.

ARIANE a été retenu pour le projet National de TAO qui a démarré en 1983 et fait l'objet du paragraphe suivant.

2.3.3.8.2 CALLIOPE[1,2]

L'objectif du projet était de réaliser et de commercialiser un ensemble de produits diffusés auprès de l'industrie, à partir des résultats obtenus par le GETA. L'ensemble de ces produits a été baptisé CALLIOPE.

Les caractéristiques originales en sont :

Abandon du lange pivot : L'idée d'un langage universel et non ambigu qui permettrait de passer lors de l'analyse, d'un texte source à une représentation en langage pivot, puis, lors de la génération, du langage pivot à la langue cible, a toujours été séduisante. L'intérêt de la stratégie est l'économie que l'on peut alors réaliser dans l'élaboration de systèmes multilingues. Le Projet National contourne les difficultés insurmontables de définir un tel langage en décomposant le processus de traduction en trois phases distinctes : analyse, transfert et génération, le transfert assurant la transition entre l'analyse aussi poussée que possible et la génération.

Les SLLPs (Specialized Languages for Linguistic Programming)[3] : Le projet prévoit la mise au point de langages spécialisés pour la programmation linguistique.

---

(1) **O. VAISSADE** : "Le projet national de traduction aidée par ordinateur et le système Calliope" in *Encrages*, n°17, Journées européennes de la traduction professionnelle, 1987
(2) **C. BOITET** : "The French National MT-Project : Technical Organization and Translation Results of CALLIOPE-AERO", *IBM Conference on Translation Mechanization*, Copenhague, août 1986
(3) **J. CHAUCHE** : *Transducteurs et arborescences. Etude et réalisation de systèmes appliqués aux grammaires transformationnelles*. Thèse d'état, Grenoble, 1974

Une linguistique développée permet d'atteindre un meilleur niveau de traduction. Les ambiguïtés sont étudiées le plus tard possible, l'analyse dépasse la syntaxe de surface, l'étude grammaticale très poussée permet d'éviter les dictionnaires gigantesques. Les informations syntaxiques et sémantiques acquises au cours de cette phase et fournies pour le transfert constituent une aide précieuse pour le choix de la traduction juste. En génération, le lexique est organisé en familles dérivationnelles. La compréhension est implicite : elle n'utilise pas de connaissances extralinguistiques entrées sous forme de représentation explicite du domaine traité et ne dispose pas de connaissances pragmatiques.

Les dictionnaires sont de deux types :
- le dictionnaire de base contient le noyau de la langue.
- les dictionnaires terminologiques sont spécialisés par domaine.

Ils contiennent les données morphologiques (pluriel, classe de conjugaison, type de déclinaison), les données syntaxiques (liste des constructions possibles pour le terme) et les données sémantiques (traits sémantiques, valences sémantiques).

Les termes sont rangés par famille dérivationnelle ou référence lexicale.

Processus de traduction

L'analyse morphologique analyse les termes en recherchant les structures base + désinence (*install-ation*).
L'analyse structurale détermine la construction grammaticale de la phrase. L'application des règles de grammaires modifient progressivement l'arborescence. Empruntons l'exemple[1] : *le remplacement du joint s'effectue sans démonter le raccord*

La phrase réflexive passive aura la représentation sivante :

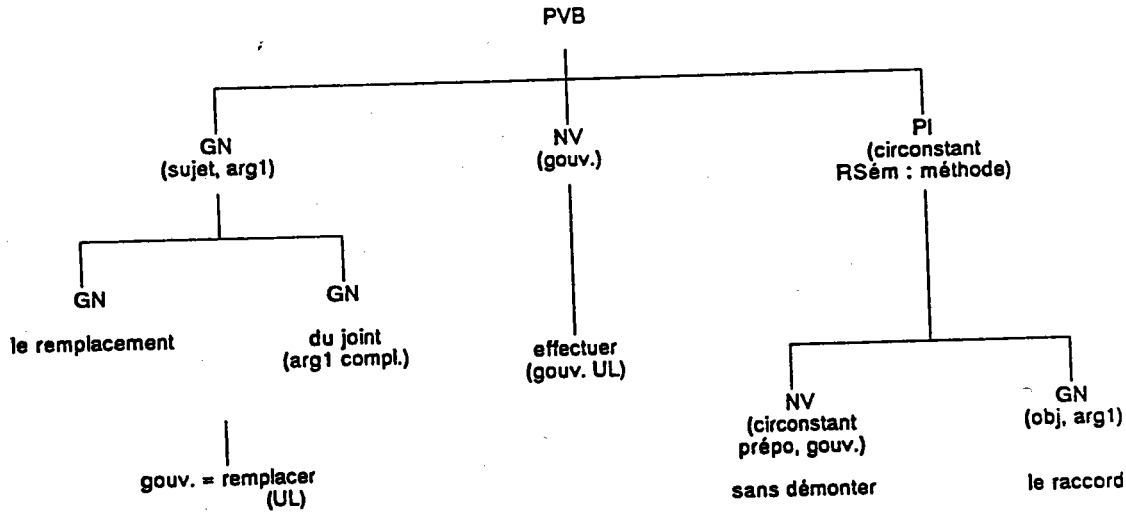

PVB : proposition verbale
NV : noyau verbal
UL : unité lexicale

GN : groupe nominal
PI : proposition infinitive

(1) extrait d'un document réalisé par la société SG2, maître d'oeuvre du Projet National de TAO, février 1987

L'analyse structurale cherche à mettre en évidence la syntaxe profonde du texte sous forme de relations logiques et sémantiques.
Le transfert lexical remplace chaque terme par un ou plusieurs équivalents de la langue cible. Les dictionnaires de transfert déterminent les choix.
Le transfert structural parfait le transfert lexical lorsque le choix d'un terme ne peut s'opérer qu'en fonction du contexte et effectue les transformations contrastives entre les deux langues. Si des ambiguïtés subsistent, le système retient la traduction la plus fréquente et proposera les autres au traducteur.
La génération syntaxique fixe la syntaxe qui sera retenue dans la langue cible.
La génération morphologique donne aux mots leur forme définitive.

Le système **CALLIOPE** peut être ainsi représenté :

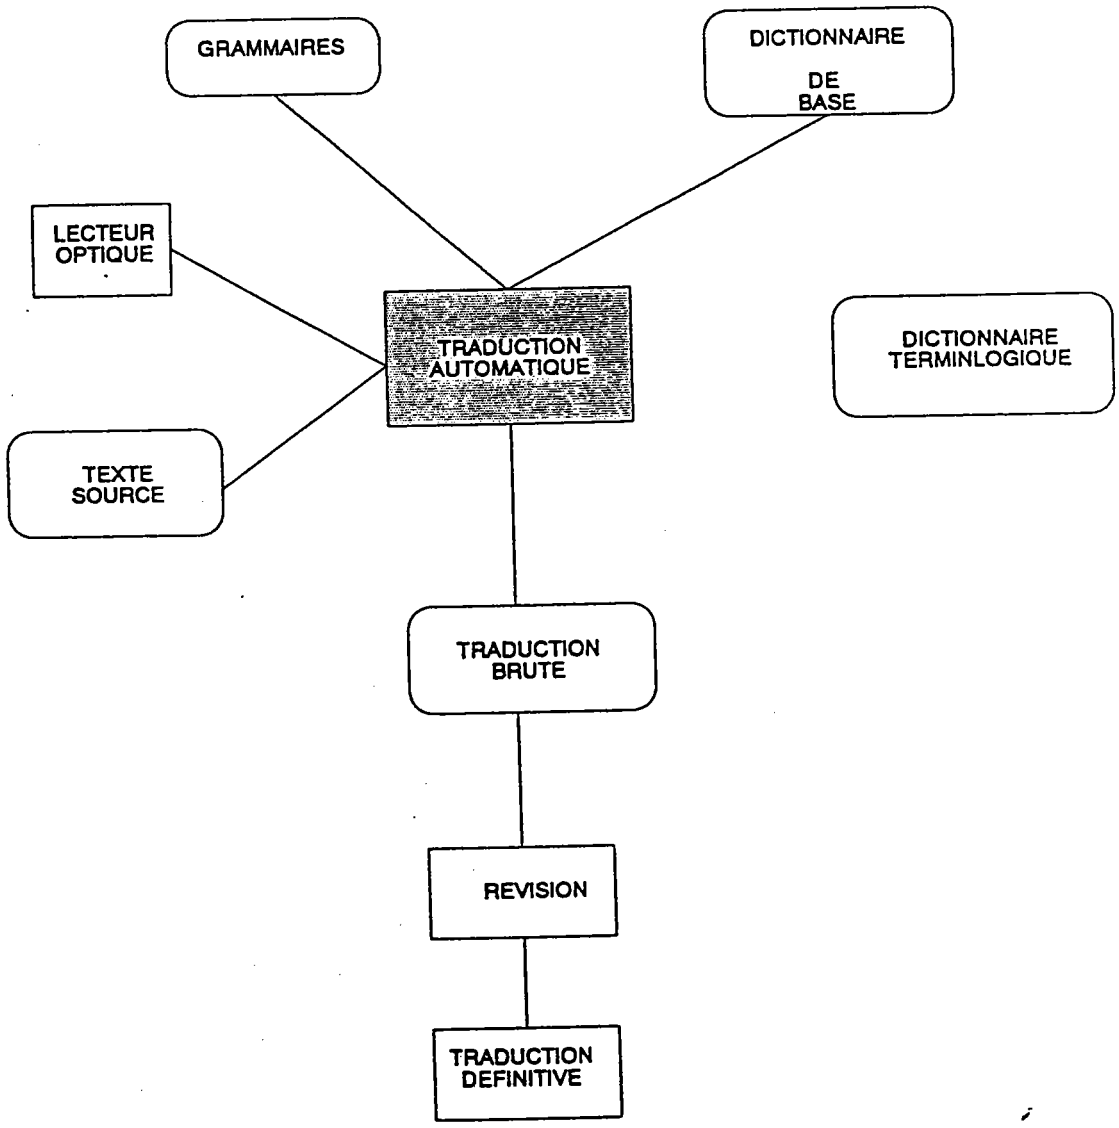

Multilingue, et fondé sur la méthode analyse-transfert-génération, il utilise le concept des systèmes experts :

- un moteur d'inférence ou de déduction qui est indépendant des langues traitées.
- une base de faits qui est la représentation de l'arborescence étiquetée.

- une base de règles ou base de connaissances linguistiques constituée par les grammaires et spécialisée par domaine.

Fonctionnement

- saisie du texte : OCR (document fourni sur support papier) ou traitements de textes divers selon environnement bureautique de l'entreprise.
- préparation éventuelle du texte s'il a été saisi par OCR ou si l'on désire ne pas en traduire une partie.
- recherche des mots inconnus au cours de l'analyse morphologique du texte. Obtention d'une liste des mots inconnus triés par fréquence, ordre alphabétique et contexte.
- indexation interactive de la terminologie
- traduction automatique
- révision de la traduction brute sur écran partagé
- traduction manuelle si cela est souhaité

L'ensemble CALLIOPE, est constitué des produits suivants :

- CALLIOPE-SYSTEME : Moteur de traduction basé sur un système-expert indépendant des langues traduites. Les bases de connaissances linguistiques sont limitées à l'aspect linguistique et ne tiennent pas compte du domaine. Le système fonctionne sur matériel IBM sous VM/CMS. La puissance minimale du matériel est de 1 MIPS, (1 million d'opérations par seconde).

- CALLIOPE-REVISION est un environnement de travail pour traducteur. Une pré-édition est nécessaire pour isoler une portion de texte qui ne doit pas être traduite ou corriger un document saisi par lecteur optique. Le traducteur peut dialoguer avec le système pour corriger la traduction brute. L'affichage se fait sur écran partagé avec un défilement synchronisé des textes source et cible. Les dictionnaires sont accessibles pendant la révision ou pendant une phase de traduction manuelle. Les accès peuvent être soumis à un système de priorités pour contrôler les mises à jour. Le produit s'insère sans problème dans le système bureautique d'une entreprise. Des systèmes de conversion assurent la compatibilité des traitements de textes et la saisie par OCR permet d'utiliser des documents fournis sur support papier. Des procédures de partage d'écran et de manipulation de chaînes de caractères donnent la possibilité au traducteur de travailler en manuel, sans recours à la traduction automatique. Le système est opérationnel sur micro-ordinateur BULL QUESTAR 400. Une installation comprend une à quatre stations de travail qui peuvent partager des ressources communes (dictionnaires, imprimantes, lecteur optique - DEST 2XX de la société WALTON -, télécommunications).

Le système de traduction se limite aux traductions techniques. Il est spécialisé par domaines.

- CALLIOPE-AERO : les modules linguistiques de CALLIOPE sont spécialisés par domaines. Le module spécialisé en aéronautique traduit du français vers l'anglais.

- CALLIOPE-INFORMATIQUE : Spécialisé en informatique, il traduit de l'anglais vers le français. Ces deux systèmes sont portables, c'est à dire qu'ils peuvent être implantés sur n'importe quelle machine. Les logiciels sont écrits en LISP.

La phase d'expérimentation a montré que le système impliquait un gain évident au niveau de l'homogénéité des traductions et que le niveau de traduction était inégal selon les textes. A la suite de problèmes d'organisation, ces travaux ont été arrêtés en 1987.

Exemple de traduction par CALLIOPE-AERO :

ILLUSTRATION DE LA PUISSANCE LINGUISTIQUE ET DE LA TYPOLOGIE DE CALLIOPE	
Effectuer un examen complet de l'échangeur de température et s'assurer de l'étanchéité dans le circuit d'air à refroidir.	*Examine in a full* [AMBIGU : complete] *manner the temperature intersection and check the leaktightness in the air flow to be cooled.*
Effectuer la vidange générale et la purge de carburant (voir chapitre 12).	*Perform general defuelling and the fuel bleeding (see chapter 12).*
Ouvrir progressivement le robinet (3) jusqu'à obtenir une pression de 9 bars.	*Gradually open tap (3) until a pressure of 9 bars is obtained.*
Brancher une source extérieure de courant mais sans alimenter les réseaux de bord.	*Connect* [AMBIGU : plug in] *external power supply but without applying power to the aircraft systems.*
Avant de déposer ou de reposer le panneau central intrados de voilure, il est nécessaire de procéder à certaines modifications.	*Before removing or reinstalling the lower central wing* [AMBIGU : *] *panel, it is necessary to proceed with some modifications.*
La pose du bouchon de protection s'effectue en comprimant le ressort par déplacement de la bague.	*The protection trap installation is carried out compressing the spring by ring movement.*
08 Vérifier, à chaque poste, l'allumage du voyant CAUTION ambre.	*08 Check, at each station, that the amber CAUTION light is switched on* [AMBIGU : ignited]
$$$ 08 Vérifier, à chaque poste, l'allumage du voyant CAUTION ambre. $$$	[Inconnu : 08 Vérifier à chaque poste, l'allumage du voyant CAUTION ambre]
Vérifier le bon fonctionnement de la jonction bloc frein et raccord de tuyauterie.	*Check the validity of the junction block brake and piping coupling.*
Soumettre le raccord à une pression de 3 + 0.5 bars.	*Subject the coupling to a pressure of 3 + 0.5 bars.*
Matériel nécessaire. Un bouchon 15-88774-101 Liquide d'utilisation AIR3520B	*Necessary equipment.* *A trap 15-88774-101* *Use fluid AIR3520B.*
Ouvrir la porte. L'opérateur la porte sur le support.	*Open the door.* *The operateur carries* [AMBIGU : wears] *it on the support.*

2.3.3.9 LUTE (Language Understander Translator Editor)[1]

Ce projet de NTT (Nippon Telegraph and Telephone) a démarré en 1981 et constitue une des expérience les plus avancées actuellement. LUTE est un système à transfert, pour les couples japonais-anglais et anglais-japonais, basé sur les techniques de l'Intelligence Artificielle. Il s'agit avant tout de recherche fondamentale destinée à définir le rôle des connaissances linguistiques et non-linguistiques dans chaque phase de la traduction.

---

(1) H. NOMURA, S. NAITO, Y. KATAGIRI, A. SHIMAZU : "Translation By Understanding : A Machine Translation System LUTE", *Proceedings of the 11th ICCL*, COLING 86, Bonn, West Germany, 25-29 August 1986, pp. 621-626

2.3.3.10 MARIS (Multilinguale Anwendung von Referenz-Informationssystemen)[1]

Ce projet a démarré en 1985 à l'université de Sarrebruck, avec l'ambition de développer un système multilingue de traitement de l'information à l'usage de germanophones qui souhaiteraient consulter des documents rédigés en anglais. Les premiers travaux concernent un système de traduction assistée par ordinateur appelé STS (Saarbrückener Translation Service), pour le couple anglais-allemand seulement. Son champ d'action est limité aux résumés et aux titres d'articles de revues.
Le développement est prévu en trois phases :
- système de traduction manuelle avec la possibilité pour le traducteur d'accéder à des banques terminologiques automatisées.
- recherche automatique de la terminologie
- système de traduction complètement automatique, appliquant la méthode du transfert et basé sur le système expérimental SUSY, développé à Sarrebruck. Domaines privilégiés : construction, environnement, normes, sciences sociales. Langues prévues : français-allemand, allemand-français.

2.3.3.11 Autres projets[1,2]

Il est impossible d'être exhaustif en la matière. Les projets cités en 3.3.5 sont les plus intéressants ou les plus importants. Certaines langues orientales commencent à faire recette et concernent des projets que nous ne mentionnerons pas tous. Nous pouvons cependant ajouter, dans l'ordre alphabétique :

- AIDTRANS : système de TAO, japonais-anglais, université de Sheffield

- ASCOF[3] : système français-allemand (recherche pure), université de Sarrebruck

- ATT (Automatic Translation Telephone) : projet de KTC (Key Technology Centre), NTT (Nippon Telephon Technologies) et KDD (communications internationales au Japon).

- CADA (Computer Assisted Dialect Adaptation) : système de traduction assistée par ordinateur pour des dialectes voisins, Amérique du sud.

- **Université de Carnegie-Mellon :**
un projet de traduction automatique avec base de connaissances,
un projet conjoint avec IBM et Hewlett-Packard,
un projet avec des fabricants japonais d'ordinateurs dans le domaine de l'Intelligence Artificielle et de la compréhension de textes.

- **Chine** : projets conduits par des universités et des organismes d'état. A Peking, un système anglais-chinois, à Shangaï, un système interactif chinois-anglais, à Taïwan, un système anglais-chinois.

- CONTRAST (Context Translation System) : système expérimental, Tokyo.

---

(1) **S. MELI** : "Informationsmarkt der maschinellen Übersetzung" in *Terminologie et Traduction*, Commission des Communautés Européennes, n°3, 1989, pp. 97-105

(2) "Ten Years of Translating and the Computer, Report on the tenth annual Translating and the Computer conference, London, November 1988, in *Language International*, vol. 1, Issue 1, 1989

(3) **A. BIEWER, C. FENEYROL, J. RITZKE, E. STEGENTRITT** : "ASCOF - A modular Multilevel System for French-German Translation" in *Computational Linguistics*, vol.11, April-September 1985

- **CSK** (CSK Research Unit) : système anglais-japonais pour les besoins propres de la société.

- **ENTRA** : projet de système anglais-norvégien en collaboration avec WEIDNER, à l'université de Bergen, en Norvège.

- **IBM** (Espagne-Israel) : système anglais-espagnol et anglais-hébreux pour les besoins propres d'IBM.

- **ICL** (International Computers Ltd.) : projet anglais de traduction automatique des Telex, anglais-français, anglais-allemand

- **NAAAT** (The National Agency for the Assessment and Application of Technology) : projet indonésien d'un système de TAO anglais-indonésien.

- **JETR** : projet de système de traduction avec base de connaissances, université de Californie (Irvine).

- **KIT** (Künstliche Intelligenz unt Textverstehen) : Technische Universität Berlin.

- **Corée** : développement de nombreux projets, coréen-anglais et anglais-coréen sutout, dont un entre IBM et l'université de Seoul, anglais-coréen et basé sur la méthode de transfert.

- **LAMB** : projet de CANON (Japon), japonais-anglais, basé sur la méthode de transfert et l'utilisation d'une base de connaissances.

- **Malaisie** : collaboration entre l'université de Malaisie et le GETA de Grenoble pour un système anglais-malais adapté à des textes d'informatique et la mise au point d'une station de traduction.

- **NASEV** (Neue Analyse- und Syntheseverfahren zur maschinelen Übersetzung) : projet de recherche théorique (dans le cadre d'EUROTRA) du BMFT ((Bundesministerium für Forschung und Technologie) réunissant les universités de Berlin, Bielefeld et Stuttgart.

- **NARA** : projet de l'université de Tokyo, sur le coréen-japonais et le japonais-coréen.

- **NIPPON** : système à usage interne de NDGC (Nippon Data General Corporation, anglais-japonais.

- **NTRAN** : système interactif anglais-japonais de l'UMIST (University of Manchester Institute of Science and Technology).

- **PAROLE** : système à transfert, japonais-anglais, de Matsushita (Japon)

- **ROSETTA** : système multilingue expérimental de Philips à Eindhoven aux Pays-Bas. Un des rares exemples de projets, hors Japon, impliquant l'industrie (tout comme SIEMENS et IBM). Les travaux ont commencé en 1980 pour aboutir à une première tentative de traduction néerlandais-anglais et néerlandais-espagnol (ROSETTA 3). Le développement du système opérationnel est l'objectif de ROSETTA 4.

- **SEMSYN** (Semantische Synthese) : à Stuttgart, système de traduction automatique des titres de revues sur les technologies de l'information, japonais-allemand.

- SEPPLI : projet de l'ISSCO (Institute for Semantic and Cognitive Studies) à Genève d'un système de traduction automatique d'offres d'emploi, allemand-français, allemand-italien.

- SERI (System Engineering Research Institute) : projet commun du GETA avec la Corée d'un système anglais-coréen, français-coréen.

- SUSY, SUSY II[1] : projet de système multilingue à transfert (université de Sarrebruck).

- SWETRA : projet suédois de système multilingue.

- TEXTUS : système anglais-français, français-anglais de l'université de Georgetown.

- TRANPRO : projet anglais d'un ensemble de traitement de texte multilingue.

- **Thaïlande** : projet commun avec la Malaisie d'un système anglais-thaï.

- **Uuniversité de Prague** : Lexiques et traduction assistée par ordinateur.

- TUMTS : université de Tamil, (Inde du sud), système de traduction directe, pour le couple russe-tamoul, adapté à des textes sur l'astronomie.

- VALANTINE : système à usage interne, KDD (Japon).

- XTRA : université du Nouveau-Mexique, système anglais-chinois.

2.4 Les services de traduction

En dehors d'institutions nationales, de bureaux privés de traduction plus ou moins importants et de traducteurs "libres" utilisant des systèmes de TA ou de TAO, nous citerons 7 cas qui semblent confirmer les prévisions de F. ZIRKLE, président de ALPS, et selon lequel les bureaux certes compétents mais de petite taille et dispersés seront progressivement remplacés par des sociétés mondiales, à intégration verticale, avec des équipes importantes de traducteurs "maison" et une gestion globale.

1. ALPNET : Cet ensemble de 9 sociétés de traduction, avec 22 bureaux répartis dans le monde propose à ses clients des traductions réalisées en partie avec le système ALPS (2.3.3.4.1).
2. BRAVICE : Créée par T. Yamamoto[2] après le rachat du système WEIDNER en 1979, la société est implantée à Tokyo et propose des traductions sur le système WEIDNER (2.3.3.2.11) qu'elle commercialise et qu'elle a vendu à plus de 3000 exemplaires dans le monde. Des bureaux ont été ouverts à Londres, Toronto, Miami et Shangaï en joint-venture avec une compagnie chinoise, en attendant Paris, Seoul et Francfort.
3. CSATA : Ce centre italien travaille avec SYSTRAN (2.3.3.2.9)
4. ECAT (European Centre for Automatic Translation) : Le centre est au Luxembourg.
5. Mendez Service Bureau : implanté à Bruxelles et propose des traductions sur SYSTRAN.
6. SOCATRA (Société Canadienne de Traduction Assistée) : La société implantée au Canada à Montréal dispose de son propre système (SOCATRA). Mis au point par son fondateur, C. RICHARD, il fonctionne sur le couple anglais-français à une vitesse de

---

(1) H.-D. MAAS : "SUZY I und SUZY II, Verschiedene Analysestrategien in der maschinellen Übersetzung" in *Sprache und Datenverarbeitung*, SDv 1-2/1981, pp. 9-15

(2) *Dynasteurs*, novembre 1987, pp 54-55

60 000 mots/heure. Le client fournit le texte à traduire et récupère une sortie brute qu'il peut réviser lui-même ou qui sera révisée sur place par une équipe de traducteurs.
7. SYSTRAN S.A. : à l'initiative de J. Gachot, le système SYSTRAN est disponible par Minitel ou accessible par modem.

2.5 Les banques de données terminologiques

Utilisées par le traducteur, elles n'ont bien sûr rien à voir avec les dictionnaires des systèmes de traduction automatique. Leur contenu se limite aux formes de base étendues à des définitions et des mises en contexte.
Le *Directory of Online Databases*[1] recense 3800 banques de données dont 3 seulement ne sont pas monolingues et s'adressent aux traducteurs. Il faut cependant souligner que le classement du Directory repose sur des critères contraignants. Il existe en fait un plus grand nombre de banques multilingues. Pour ne citer que les plus importantes :

- AEROSPACE TERMINOLOGY : anglais, français et allemand
- EURODICAUTOM : toutes les langues de la Communauté Européenne, pour tous les domaines.
- LEXIS : Bundessprachenamt à Bonn.
- SMART TRANSLATORS : expressions techniques de l'anglais vers l'allemand, l'espagnol, l'italien et le russe.
- TEAM chez SIEMENS
- TERMIUM à Montréal

2.6 Conclusion

L'idée de traduction automatique remonte à l'origine des ordinateurs. Elle ne jouit cependant d'une reconnaissance scientifique que depuis quelques années, grâce à une poignée d'applications réussies, une augmentation de la demande (les besoins augmentent de 15% par an) et une évolution du type de traductions exigées.

Les systèmes existants ont pour la plupart vu le jour aux Etats-Unis, entre les années 60 et 70. Ils entrent dans deux catégories de base : les systèmes complexes implantés sur des gros calculateurs, centralisés et interrogés à distance (LOGOS, SPANAM et SYSTRAN), et les systèmes plus simples (SMART, WEIDNER et LINGUISTIC PRODUCTS) qui fonctionnent sur des micros, chez l'utilisateur.
La qualité des résultats dépend des couples de langues traitées, du type de document et de la base terminologique disponible. La couverture des langues est assez complète, la majorité des systèmes opérationnels couvrant le français et l'anglais dans les deux sens, l'allemand et l'espagnol en langue source ou en langue cible. L'anglais est la langue source la plus développée.
Les utilisateurs appartiennent à deux catégories : ceux qui analysent les textes en langue étrangère pour des besoins d'information (l'US Air Force avec SYSTRAN depuis 1970, à partir du russe, du français et de l'allemand et le Centre de Recherches nucléaires de Karlsruhe, du français vers l'anglais) et ceux qui traduisent des documents dans l'optique d'une diffusion multilingue (traduction des manuels de maintenance chez XEROX, FORD, IBM, Dornier et Siemens). Dans le premier cas, la traduction brute est confiée à des experts des différents domaines qui se contentent de traductions de moyenne qualité sans révision humaine, dans le second cas, un niveau de qualité élevé est exigé, qui sous-tend une préparation soignée des documents sources, une termi-

---

(1) Directory of Online Databases, Vol. 9, n° 3, juillet 1988

nologie technique fiable et une post-édition humaine. Les avantages essentiels sont la rapidité, la cohérence et le coût. En ce qui concerne le secteur public, les grandes institutions ont recours à la T.A. (l'OTAN, certaines agences de l'ONU et la Commission Européenne) pour traduire des rapports techniques, des documents administratifs et des compte-rendus de réunion. La qualité des traductions brutes est rarement satisfaisante, mais une post-édition rapide (4 pages/heure) fournit des résultats acceptables. En France, la traduction automatique a fait son apparition sur le réseau Minitel où GACHOT S.A. propose des services en direct sur SYSTRAN. La majorité des textes soumis ressemblent à ceux du Minitel Rose[1]. L'originalité du vocabulaire explique sans doute la qualité médiocre des traductions.

Les tendances sont inégales. En général, les fabricants de systèmes ont été dépassés par les événements. Leurs investissements sont allés au delà du potentiel qu'offre le marché actuel. LOGOS a perdu de gros clients au Canada, ce qui l'a obligé à réduire ses efforts de développement linguistique. WEIDNER a cessé ses activités en Amérique du Nord et en Europe, la société mère (BRAVICE) continuant au Japon. ALPS plutôt spécialisé en T.A.O. a également dû se limiter à des services généralisés en traduction et ne vend pratiquement plus de logiciels. SMART a beaucoup de succès en Amérique du Nord, pour la traduction de manuels de maintenance technique et d'avis de vacances d'emploi. Il offre depuis peu le couple anglais-grec. Le logiciel développé par la firme texane Linguistic Products, qui tourne sous MS-DOS pénètre rapidement le marché grâce à un prix très compétitif (100 logiciels vendus en 1988). SYSTRAN progresse à l'OTAN, chez XEROX et dans l'US Air Force. Les grandes entreprises japonaises, enfin, ont toutes développé des systèmes qui sont maintenant opérationnels pour les couples anglais-japonais et japonais-anglais.

La recherche évolue. Les avancées les plus notables sont à porter au crédit des principaux fabricants japonais d'ordinateurs. Les systèmes anglais-japonais et japonais-anglais sont nombreux. Fujitsu est au dessus du lot avec son système ATLAS. En Europe, le projet principal est EUROTRA, cofinancé par la Communauté Européenne et ses états membres. Des systèmes pilotes sont attendus pour 1995. Il ne faut cependant pas oublier d'autres projets avec DLT aux Pays-Bas et METAL créé au Texas mais maintenant développé par Siemens à partir de l'allemand. Aux Etats-Unis, IBM s'intéresse de nouveau à la T.A. et travaille à partir de l'anglais vers l'espagnol, l'hébreu et le finlandais. Dans l'ensemble, les résultats sont décevants, (le projet CALLIOPE a été suspendu, les systèmes japonais buttent sur de nombreux obstacles et EUROTRA connaît des difficultés de coordination en ce qui concerne les travaux de ses différentes équipes). Tout ceci explique sans doute pourquoi les approches classiques ont toujours rencontré plus de succès que les stratégies d'innovation reposant sur des théories linguistiques difficilement programmables.

Si l'on souhaite dresser une échelle de réussite de tous ces systèmes, l'examen des résultats conduit à fixer un ensemble de critères d'évaluation[2]. Il est difficile cependant d'effectuer une analyse complète et fiable des documents, dont on regrettera qu'ils ne soient pas toujours accessibles et significatifs. La matière est au contraire abondante en ce qui concerne les systèmes "reconnus". On constate alors que les systèmes à sémantique fermée (TAUM) ou à syntaxe contrôlée (TITUS) s'imposent devant SYSTRAN qui, si on voulait l'affranchir de ces contraintes, deviendrait un système gigantesque. C'est ce qui fait l'intérêt de notre Automate de Compréhension Implicite, qui accepte une sémantique ouverte et fournit une sortie moins ambitieuse.

---

(1) Entretien avec **Ian M. PIGOTT**, responsable des développements SYSTRAN, Commission des Communautés européennes

(2) **G. Van SLYPE** : "Conception d'une méthodologie générale d'évaluation de la traduction automatique" in *Multilingua*, Mouton, 1-4/1982

III.

UN SYSTÈME D'INTERPRÉTATION AUTOMATIQUE : L'AUTOMATE DE COMPRÉHENSION IMPLICITE (ACI)

Les deux premiers chapitres donnent une idée des techniques utilisées en T.A.L.N., de leurs applications et des résultats obtenus. Dans ce chapitre III, nous proposerons une autre approche, avec **l'Automate de compréhension Implicite** (ACI). Ce système a été mis au point dans le cadre du Centre de Recherche Jean Favard. Nous le situerons d'abord par rapport à la T.A. et à la T.A.O., avant d'en détailler les principes, les caractéristiques puis la structure d'ensemble. La réalisation complète n'a pas été menée à terme, aussi les sorties que nous présentons au paragraphe 3.2.2.2 et en conclusion (p. 668) ne sont-elles qu'une simulation. Le chapitre IV sera consacré à la description exhaustive des modules responsables de l'analyse, dans le contexte germanique-roman, pour respecter les limites de notre sujet.

3.1 Le contexte

3.1.1 Analyse des systèmes et évolution

3.1.1.1 De 1950 à 1970

Au cours de ces 20 premières années, le domaine de la TA a connu des fortunes diverses (2.3.1), allant de l'euphorie générale à une paralysie quasi-totale (Rapport ALPAC). L'idée était d'employer la rapidité de calcul et la mémoire des ordinateurs pour associer un mot d'une langue à un mot d'une autre langue puis d'obtenir une traduction automatique à peu près correcte, moyennant un léger réarrangement (ordre des mots en particulier). *Il est clair que la traduction ne concerne ici qu'un couple de langues et ne s'effectue que dans un sens. L'analyse de la langue source dépend de la langue cible.*

E. REIFLER tente une traduction automatique à l'aide de la machine de KING[1] à l'Université de Wahington (Seattle). Il s'agit d'une traduction mot à mot réalisée par un automate transducteur d'états finis qui lit en entrée un symbole et renvoie une chaîne de sortie. C'est en fait une consultation de table (un lexique) qui possède a priori le meilleur correspondant pour un mot polysémique. *Un tel système ne peut lever les ambiguïtés.*

Le système de KULAGINA et MEL 'CUK est infiniment plus évolué. Il fonctionne sur un ordinateur classique des années 1955-1960 et traite un corpus de textes mathématiques (250 expressions idiomatiques et 1300 mots différents). Le processus en deux étapes (analyse du texte d'entrée et synthèse du texte de sortie) préfigure les méthodes de 2ème génération. La partie lexicologique est organisée en 3 dictionnaires : français, russe et dictionnaire d'expressions idiomatiques. Le premier dictionnaire contient des bases associées à des indications concernant leur identification, le caractère idiomatique, l'existence d'homonymes, de traductions multiples le cas échéant, les traits morphologiques et syntaxiques. Le programme réalise une traduction en 5 étapes (recherche des mots dans le dictionnaire français, traitement des expressions idiomatiques, résolution des homographies, analyse de la phrase française, synthèse de la phrase russe).

Le système de la Georgetown University, opérationnel depuis 1963-1964 est d'un type voisin. Il repose sur un dictionnaire de bases qui peut posséder plusieurs mots équivalents et un processus qui, après consultation du dictionnaire, réalise une analyse morphologique, une analyse syntaxique (traitement des constituants contigus) suivie d'un transfert vers l'anglais, d'un réarrangement des mots et insertion de particules. *Ce système a la particularité de pouvoir traiter les mots inconnus. L'ensemble de travaux qui concernent cette période se caractérise par une focalisation sur les problèmes lexicaux et une absence complète de théorie linguistique.*

---

(1) La machine photoscopique de G. KING (IBM) est à notre connaissance la seule tentative "hardware" de traduction automatique.

Un commentaire de L. DOSTERT, cité par B. VAUQUOIS[1] traduit les faits : "La traduction est une affaire de mémoire (storage) et d'intelligence ; la mémoire, c'est le dictionnaire ; l'intelligence, c'est le programme". Remarquons au passage que le rapport ALPAC paru en 1966, c'est à dire au milieu de la période de 2ème génération, ne concerne pas du tout celle-ci, mais uniquement les travaux de 1ère génération pour lesquels *toute insertion dans les programmes provoque des réactions insoupçonnées et dont la perfectibilité est effectivement très douteuse.*

Les études de D.G. HAYS sur la théorie des constituants et sur celle des dépendances pour le calcul des structures syntaxiques vont contribuer au lancement de la seconde génération, caractérisée par la distinction des trois phases : ANALYSE, TRANSFERT et GENERATION. *Les tâches sont désormais séparées et indépendantes. La phase de transfert est seule à concerner un couple de langues, le choix d'un pivot judicieux permettant cependant une traduction multilinguale, quelles que soient les langues d'entrée et de sortie.* Nous pouvons schématiser la structure d'un système de 2ème génération de la façon suivante :

Analyse

- Analyse morphologique : Le texte d'entrée est considéré comme une suite de graphèmes (y compris le caractère blanc). On passe du niveau graphémique au niveau des morphes pour lesquels on peut constituer des dictionnaires ("verbal", "verbale", "verbaux", "verbales" correspondent aux morphes "verb", "al", "ale", "ales" et "aux")[2]. L'analyse a pour effet de substituer au mot une expression formée de différents éléments : une référence lexicale qui correspond dans certains systèmes à une base de dérivation, un indice de dérivation qui précise le type de dérivation, une classe syntaxique, une liste de variables grammaticales, syntaxiques (rections) et sémantiques (traits sémantiques). Le dictionnaire morphologique comprend une zone d'entrée (avec le morphe) et une zone d'information (code morphologique, code syntaxique, code d'étiquetage). Il se présente sous deux formes : bases triées par ordre alphabétique et par numéro d'unité lexicale. L'algorithme d'analyse repose sur une consultation du dictionnaire et une élimination des ambiguïtés à l'aide de l'indice de dérivation.

- Analyse syntaxique : En dehors des grammaires "en chaîne" (1.4.3.2.3), deux théories linguistiques ont la faveur des équipes pour l'étude de la syntaxe de surface : l'analyse en constituants immédiats largement utilisée aux USA et l'analyse en structures de dépendances privilégiée en URSS.

L'analyse en constituants immédiats repose sur les grammaires "hors contexte" (1.4.3.1.2) qui permettent des descriptions sous forme parenthésée. La principale difficulté réside dans l'élimination des structures parasites.

L'analyse en structures de dépendances permet de marquer qu'un mot dépend d'un autre. Elle repère sa situation linéaire par rapport à son gouverneur. Une règle initiale donne l'élément sommet du graphe (prédicat de forme verbale dans la majorité des cas). L'intérêt de débuter les recherches avec l'élément sommet du graphe est qu'il possède des relations bien étudiées avec les éléments immédiatement dépendants (arguments - compléments du verbe - appartenant au cadre verbal et soumis à des rections connues). On dispose d'une représentation parenthésée.

---

(1) B. VAUQUOIS : *La traduction automatique à Grenoble,* Documents de Linguistique Quantitative n°24, Paris, 1977, p. 29

(2) cf. supra, p. 37

Outre les analyseurs par relations de dépendances (KULAGINA à Moscou, TSEITIN et FITIALOV à Leningrad), on trouve deux autres types d'analyseurs :

L'analyseur prédictif (1.6.3.3) explore une phrase de la gauche vers la droite en avançant d'un symbole terminal qui doit réaliser la prédiction en tête d'une liste de prédictions et enregistrer en tête de liste les prédictions qu'il impose à son tour. L'hypothèse de base est qu'en tout point de l'analyse, il doit être possible de déterminer la structure syntaxique du mot qu'on est en train d'étudier, sur la base des prédictions faites pendant l'analyse des mots qui le précèdent, et d'autre part, de prévoir les structures syntaxiques que l'on rencontrera à la droite de ce mot. L'analyseur fonctionne comme un automate à pile (push-down store) qui accepte une grammaire hors-contexte sous forme de GREIBACH[1]. L'analyse prédictive a été particulièrement étudiée par OETTINGER, GREIBACH et KUNO (Harvard).

Les analyseurs syntaxiques ascendants s'appuient sur l'algorithme de COCKE. La grammaire peut être mise sous la forme normale de CHOMSKY. Cette analyse pernet de conserver toutes les parties communes des diverses analyses, ce qui n'est pas possible avec les méthodes descendantes. Si la phrase analysée est composée de *n* mots, l'arbre correspondant comportera *n-1* sommets non terminaux. L'analyse montante consiste à construire l'arborescence à partir des sommets terminaux. Cet analyseur a été utilisé par SAKAI et NAGAO à Kyoto, TAMACHI à Fukuoka, en Grande-Bretagne et à Grenoble (Au CETA, l'analyse syntaxique est réalisée au moyen d'un analyseur "Extended Context-free" qui est une variante de l'algorithme de COKE et fournit des arborescences en constituants. L'analyse se poursuit par une phase d'interprétation qui aboutit à des structures de dépendances).

Le transfert

Pour passer de l'analyse à la génération, de la langue source à la langue cible, il est nécessaire de passer par l'étape de transfert, caractérisée par l'emploi d'un *langage pivot.* Afin d'assurer une traduction multilingue, il convient de créer un pivot capable de conserver le sens au niveau le plus profond et de représenter des phrases ayant un sens identique mais éventuellement des structures morphologiques et syntaxiques différentes. Ce langage pivot est réalisé sous la forme de structures de dépendances accompagnées de variables linguistiques recherchant la valeur approximative de "cas profonds". Il fait apparaître une partition des unités lexicales en 2 classes.
- les éléments à valeur prédicative qui se comportent comme des prédicats à une, deux, trois places d'argument. L'unité lexicale de ce type, munie de ses arguments, forme un schéma d'énoncé. "Le schéma d'énoncé est la base de la structure syntaxique du langage pivot".
- les éléments à valeur non prédicative servent d'argument aux précédents. Ce sont souvent des mots descripteurs (noms propres, noms communs qui ne dérivent pas de verbes ou d'adjectifs).

La génération

A partir du langage pivot, dans l'ordre inverse, on génère une structure syntaxique (de surface) puis une structure morphologique.

---

(1) L'analyseur prédictif de Harvard (KUNO et OETTINGER) est le plus important parmi les premiers analyseurs descendants, construits sur une grammaire non contextuelle dont les règles suivent la forme normale de GREIBACH : le premier symbole de chaque membre droit doit être un symbole terminal. La grammaire utilisée ici contenait 133 classes de mots et 2100 règles. Elle ne traitait pourtant pas l'accord du sujet et du verbe et acceptait des phrases non grammaticales !

Il est intéressant de rappeler que le système du CETA, développé de 1961 à 1967 a effectué les premières traductions russe-français avec des grammaires et des dictionnaires qui ont été perfectionnés jusqu'en 1971. L'expérience a porté sur plus de 400 000 mots traduits sur IBM 7044 à la vitesse de 4500 mots/heure. Une classification des phrases selon 2 types (phrases compréhensibles et non compréhensibles) donne, sur un échantillon important de ces textes, 61% de phrases compréhensibles, 39% d'incompréhensibles.

On notera que de façon paradoxale, ce sont les systèmes de 1ère génération, améliorés mais inférieurs aux systèmes de 2ème génération, qui ont été exploités.

3.1.1.2 De 1970 à nos jours

Il semble que le coup d'arrêt apporté par le rapport ALPAC ait largement contribué au développement gigantesque de l'Intelligence Artificielle. C'est entre 1970 et 1973 qu'apparaissent les premiers travaux, avec la thèse de T. WINOGRAD et sa publication[1] en 1972. L'enthousiasme renaît et suscite un grands nombre d'études, (J. PITRAT[2] en France).

Le robot de WINOGRAD est dirigé par l'intermédiaire d'un ordinateur, en langue naturelle (anglais). Il évolue dans un monde constitué d'une table, d'une boîte et de cubes, boules, pyramides de diverses couleurs. Il manipule les objets décrits dont il connaît les coordonnées, selon les ordres exprimés en anglais. La grande originalité de ces travaux, outre que le robot répond en anglais (ce qui suppose une génération, même légère, de l'anglais), est de pouvoir, à partir des éléments introduits en mémoire, raisonner à leur sujet. Il fait preuve d'un pouvoir de déduction logique et d'inférence. Les robots de ce type (winogradiens) fonctionnent dans un univers limité, restreint. Ils possèdent leurs connaissances sous forme de dictionnaires et de relations. Le volume des informations que l'on fournit à la machine ne peut cependant pas s'accroître indéfiniment. On parle de *sémantique fermée*.

D'autres travaux sont effectués dans la même période, avec W. WOODS[3], R. SIMMONS[4] et R. SCHANK qui cherchent à traduire un texte dans une représentation différente du langage naturel et ceci à l'aide d'une analyse conceptuelle. La sortie de tels analyseurs est une représentation des concepts et de leurs relations explicites ou implicites (1.5.3.1.2 et 1.6.7). Un autre mérite de R. SCHANK est de créer un "script", structure en trois parties, pour formaliser la connaissance des étapes d'un évènement : début d'action, acteurs et objets nécessaires à l'évènement, déroulement des opérations. Comme dans nos travaux de compréhension, il est à remarquer que le point délicat consiste à repérer la fin d'un phénomène ou d'une action.

Les projets de TA menés à terme ou en voie de réalisation (2.3.3, 2.3.4) ont essayé de tirer des leçons du passé en concentrant leurs efforts sur les problèmes linguistiques plus ou moins bien maîtrisés par les théories que nous venons d'évoquer. Après une absence complète de théorie linguistique, la syntaxe s'est imposée, puis la sémantique.

---

(1) T. WINOGRAD : *Understanding Natural Language*, Academic Press, Edinburgh, 1972
(2) J. PITRAT : "La programmation informatique du langage" in *La Recherche*, n°93, 1978
(3) W. WOODS : *Transition Networks grammars for Natural Language Analysis*, CACM (Communications of the Association for Computing Machinery), Vol. 13, n°10, 1970, pp. 437-445
(4) R. SIMMONS : "Semantic Networks : their Computation and Use for Understanding English Sentences", in *Computer Models of Thought and Language*, Schank & Colby, Freeman, San Francisco, 1973, pp. 63-113

Les améliorations ne sont pas probantes, en attendant une entrée en force de l'Intelligence Artificielle, dont se réclament les systèmes récents et que nous promet le projet japonais de 5ème génération.

3.1.2 Evolution des conceptions

Nous avons vu qu'un des grands progrès accomplis avec les systèmes de 2ème génération a été de *séparer les grammaires et les dictionnaires* (les données sur la langue) du logiciel d'analyse. Ce principe est le seul qui autorise une évolution ultérieure satisfaisante. Le système ARIANE 78 (2.3.3.8.1) en est une parfaite illustration.

Une autre conclusion s'est imposée. L'ordinateur ne peut accéder à une compréhension satisfaisante que pour *un domaine bien limité.* Les systèmes performants sont le plus souvent spécialisés. TAUM-METEO (2.3.3.3.7.1) est une réussite exemplaire. La dernière version, METEO2, tout en étant plus performante que METEO1, fonctionne sur un micro-ordinateur de taille moyenne et traduit correctement 90-95% des phrases.

Les ingénieurs de l'Institut du Textile de France ont limité non seulement la sémantique mais aussi la syntaxe. TITUS IV (2.3.3.3.10) accepte exclusivement les textes rédigés selon des règles de syntaxe préétablies et ne contenant que des termes appartenant à un vocabulaire prévu. L'opérateur doit se plier à une certaine discipline et connaître le domaine. La rigueur de *la syntaxe contrôlée* garantit la clarté des textes.

D'autres voies offrent une alternative avantageuse à la Traduction Automatique. Afin d'aboutir plus sûrement à un outil opérationnel, les recherches se sont souvent orientées vers des systèmes d'aide à la traduction, recueillant les fruits des énormes progrès de l'informatique en miniaturisation et en puissance. Les ambitions sont plus réalistes. Les systèmes sont limités, *la qualité très moyenne des résultats nécessite la révision d'un traducteur qui dispose d'un environnement adapté. et gagne ainsi un temps précieux.* On distingue la traduction par ordinateur assistée par l'homme (système interactif ALPS 2.3.3.4.1, système WEIDNER 2.3.3.2.11) et la traduction humaine assistée par ordinateur (outils d'aide tels que MERCURY 2.3.3.4.2, TERMEX 2.3.3.4.3, TII 2.3.3.4.6...).

Nous pensons que ces systèmes présentent des défauts, parfois décourageants lorsqu'ils ne sont pas rédhibitoires. La convivialité n'est pas toujours le point fort de ces outils qui exigent de l'utilisateur une longue période d'adaptation. Les fabriquants livrent des dictionnaires spécialisés en option et n'autorisent pas le client à compléter les lexiques. Ils proposent des réactualisations périodiques nécessairement coûteuses. Il est tout de même parfois possible de créer son propre dictionnaire. La structure des programmes qui l'utiliseront limite les rajouts aux noms communs. Les niveaux de prix sont bien entendu fonction des performances et du matériel recommandé. Certains de ces produits tournent sur un micro-ordinateur haut de gamme (AT 386, 8 Mo de mémoire centrale, disque dur de 80 Mo, 30 000 à 40 000 F), d'autres fonctionnent sur des minis ou des calculateurs spécialisés (machines dédiées). Le logiciel est vendu ou implanté sur site avec une licence d'exploitation.

De son côté, la TA s'adapte au marché. Elle doit vaincre pour cela le handicap de sa démesure : les programmes et les données exigent une maintenance et un développement constant. Le matériel informatique nécessaire n'est pas à la portée de tous les porte-monnaie. Aussi a-t-elle recours aux techniques de partage des ressources. La télématique lui permet de communiquer, d'un site central (centre serveur) vers des périphériques (minitel, micro-ordinateurs). Elle devient prestataire de services (SYSTRAN/Gachot 2.3.3.2.9).

3.2 Une autre approche de la compréhension avec l'ACI

Les modèles linguistiques sont encore insuffisants pour que la Traduction Automatique parvienne à des résultats vraiment satisfaisants. Les systèmes qui proposent une traduction entièrement automatique exigent en fait une préédition ou une sélection préalable du document à traduire. On ne peut de toute façon jamais faire l'économie d'une révision qui s'impose quel que soit le type de système utilisé.

Si l'on considère l'aspect économique du domaine et nous pensons qu'il est essentiel, les systèmes plus modestes ont un intérêt certain. Les investissements ne sont pas démesurés, qu'il s'agisse de leur développement ou de leur exploitation. Ils ne sont efficaces que pour des domaines délimités mais l'acquisition de modules proposés en option étend quelque peu leur "couverture".

Ces limites posées, l'état des recherches en linguistique automatique et par voie de conséquence, l'insuffisance des modèles de la langue sont à l'origine d'une démarche beaucoup plus pragmatique, centrée sur la compréhension. Lorsque nous sommes arrivé au Centre de Recherche Jean Favard en 1976, D. HERAULT et P. POGNAN avaient jeté les bases du système que nous allons décrire, et développé un analyseur prédicatif du tchèque, testé sur d'autres langues slaves. Les travaux de J.P. HUBAC sur le français, de M. FANTON sur le groupe prépositionnel allemand, de H. FERVERS sur le dictionnaire de bases allemand-français et de R. SAUSSE sur le japonais ont permis de vérifier certaines hypothèses sur les principes que nous avons alors retenus. Après avoir résolu le problème de la localisation automatique des mots composés (1979) et préparé le module de désimbrication des mots d'origine germanique et d'origine romane, nous avons développé l'analyseur de l'Automate de Compréhension Implicite.

3.2.1 Définition

Nous pensons que la compréhension est un élément fondamental des systèmes de Traitement Automatique des Langues Naturelles. Il suffit de se rappeler le conseil mille fois répété de notre professeur de latin : "*Lisez plusieurs fois votre texte, avant de traduire !*" pour découvrir l'évidence ; *lire* veut dire ici *comprendre en gros* le texte. Pourquoi en irait-il autrement en T.A. ?
L'examen des livres et articles étrangers montre qu'ils ne sont pas toujours accompagnés d'un résumé dans une langue comme l'anglais, et si résumé il y a, que l'idée n'est peut-être pas toujours fidèle. Le cycle traduction-impression-édition est de plus très long, de sorte que la traduction n'a plus d'intérêt parce qu'elle date, sans compter la traduction qui ne correspondait pas aux besoins.
Partant de ces quelques constatations, l'idée a été de construire un système de "lecture rapide", de saisie du contenu, ***un système capable d'extraire automatiquement les éléments nécessaires à la compréhension d'un texte technique ou scientifique écrit dans une langue étrangère, pour un lecteur spécialiste du domaine mais ne maîtrisant pas cette langue.***

Un certain nombre de principes se sont alors imposés, au fil des recherches. Nous allons les rappeler.

3.2.2 Principes

3.2.2.1 Compréhension explicite, compréhension implicite

Nous distinguons deux types de compréhension, la compréhension explicite et la compréhension implicite.

- **la compréhension explicite** extrait du texte les informations nécessaires pour aboutir à des réalisations concrètes, tangibles (robots, systèmes experts...). Il s'agit là d'Intelligence Artificielle où l'on relève un noyau de compréhension et où l'exécution de tâches pratiques et visibles en apporte la preuve.

- **la compréhension implicite** extrait d'un texte suffisamment d'informations pour qu'un familier du domaine puisse en déduire le contenu et son organisation. Dans ce cas de compréhension implicite, c'est l'intelligence seule de l'utilisateur qui permet de savoir si le système a, ou non, fonctionné correctement.

Cette distinction implicite/explicite, qui ne devrait pas provenir de l'analyse initiale, prend un sens par rapport à la nature de l'univers sémantique dans lequel on s'est placé. **Dans un univers sémantique ouvert,** il y a toujours un résidu d'implicite (présupposition, sous-entendu...) mais, pour prendre une comparaison acoustique, le bruit de fond n'empêche pas de traiter le signal. La compréhension est explicite, sur fond d'implicite, sans que l'on puisse fixer de frontières entre les deux couches. On peut en effet plus ou moins expliciter l'implicite. **Un univers sémantique fermé** est, quant à lui, la condition d'une compréhension explicite sans "trace d'implicite".

La compréhension peut cependant devenir implicite si l'on "réduit" l'explicite comme le fait notre ACI. Le caractère implicite de sa compréhension ne tient pas seulement à l'univers sémantique dans lequel se situe le message. Il tient aussi à la destructuration relative de la langue, liée à l'exploitation de l'hypothèse du parallélisme dérivationnel des langues que nous présentons de 3.2.2.3 à 3.2.2.4.

Les systèmes de TA opèrent généralement en sémantique largement ouverte (il peut y avoir certaines limitations de domaine), mais avec des méthodes relevant de la sémantique fermée, puisque les dictionnaires, tels qu'ils sont conçus et implantés, "ferment" obligatoirement la sémantique dans laquelle le système est placé. Il en va de même pour les systèmes de Documentation Automatique qui, avec des réseaux de mots- ou d'expressions-clés, s'inscrivent dans la sémantique la plus fermée que l'on puisse imaginer. Il y a là une profonde contradiction. Partir de la compréhension permet de limiter considérablement les ambiguïtés et surtout, permet de considérer un texte dans sa totalité, chaque phrase apportant éventuellement une information. Dans la plupart des systèmes, aucune liaison sémantique n'est établie de phrase en phrase. Ces systèmes ne créent pas une mémoire de référence dans le déroulement du texte. Chaque phrase est analysée isolément. Ces arguments soulignent la nécessité d'une première étape privilégiant la compréhension pour aboutir à l'extraction d'information, quel que soit le but recherché.

3.2.2.2 Interprétation automatique

Le but de la compréhension implicite est de passer en *interprétation*, de la langue source LS à la langue cible LC.

Il convient de définir avant tout ce que nous entendons par **"interprétation automatique"** et en quoi ce concept diffère de "traduction automatique". Un système d'interprétation ne cherche pas à traduire, il essaie d'extraire de tout texte (non-littéraire) suffisamment d'informations pour qu'un utilisateur du système, connaissant bien le domaine dont parle le texte, en *comprenne* convenablemant le contenu. La différence avec la notion de traduction repose sur la nécessité de compréhension et les compétences de l'utilisateur. Cette hypothèse ne nous semble pas trop restrictive dans le sens où un spécialiste ne s'intéressera pas souvent à un domaine très éloigné du sien. Ceci a une conséquence immédiate : les problèmes d'ambiguïté peuvent être considérablement réduits, cela permet de proposer à l'utilisateur un texte interprété compréhensible, écrit

dans sa langue, mais d'une mauvaise qualité linguistique (des problèmes délicats peuvent en effet être traités de façon plus superficielle : traduction des prépositions...). De nombreux tests ont montré qu'à partir des informations données, l'utilisateur reconstruit le texte initial. Nous sommes loin de la traduction qui n'exige pas la participation du lecteur et dans cette optique, nous pouvons même dire que la T.A.O. est en quelque sorte à mi-chemin entre la T.A. et l'interprétation.
Voici quelques exemples d'interprétations obtenues par simulation sur notre texte d'essai :
Man kann diese Spannung messen, wenn man die Kohlestäbe außerhalb des Gefäßes durch ein Voltmeter verbindet.

```
00023000100000   *05 MAN                 On
0V002000200000 4300 KANN                peut
*V002000500000 2130 MESS                mesurer
000230003ON003   V00 DIESE              cette
000230004*N003   $00 SPANN.UNG          tension
00023000600000   ,01 ,                  ,
000230007OC007   N00 WENN               quand/si
00023000800000   *05 MAN                on
.V0170017*C007 2300 VERBIND             relie
000230009ON009   IVK DIE                les
000230010*N009   $00 STA*B.E KOHLE       tige carbone
000230011OP011   P00 AUS*ERHALB         en dehors de/du
00023001200000   I00 DES                le
00023001200000   I00 GE.FA*S*.ES         récipient
000230014OP014   P00 DURCH              par
00023001500000   J00 EIN                un
000230016*P014   $00 VOLT METER          voltmètre
00023001800000       .                  .
```

Tatsächlich erhält man infolge von Energieverlusten in der Zelle jedoch nur zwischen 0,6 und 0,85 Volt.

```
00019000100000   AZ0 TATSA*CHLICH       En fait
00019000300000   *05 MAN                on
.V002000200000 2300 ERHALT              obtient
0001900040P004   P00 INFOLGE VON        à la suite de
000190005*P004   $00 VER.LUST.EN/EN.ERG.IE perte d'énergie
0001900060P006   P00 IN                 dans
00019000700000   I00 DER                la
000190008*P006   $00 $ZELLE             cellule
00019000900000   A00 JEDOCH             pourtant
00019001000000   A00 NUR                seulement
0001900110P011   P00 ZWISCHEN           entre
00019001200000   C00 0,6                0.6
00019001300000   M0+ UND                et
00019001400000   C00 0,85               0,85
000190015*P011   $00 $VOLT              volt
00019001600000       .                  .
```

An der Anode bewirkt ein Katalysator die Aufspaltung der Wasserstoff-Moleküle in Wasserstoff-Ionen (H+) und Elektronen (e).

```
0001100010P001   P00 AN                          A
00012000200000   I00 DER                         l'
000130003*P001   $00 AN.OD.E                      anode
0001100050N005   JS0 EIN                         un
000110006*N005   $00 KATA.LYS.ATOR                catalysateur
.V004000400000 1380 BEWIRK                       effectue
0001100070N007   IVK DIE                         la
00011000800000   $00 AUF.SPALT.UNG               séparation
00011000900000   IVK DER                         des
000110010*N007   $00 MOLEK.U*L.E WASSERSTOFF      molécule hydrogène
0001100110P011   P00 IN                          dans/en
00011001200000   $00 ION.EN WASSERSTOFF          ion hydrogène
000110013+0000       (                           (
000110014#0000   $00 H+                          H+
000110015&0000       )                           )
00011001600000   M0+ UND                         et
00011001700000   $00 ELEKTRON.EN                 électron
000110018+0000       (                           (
000110019#0000       E                           e
000110020*P011       )                           )
00011002100000       .                           .
```

Die Größe eines aus ihnen konstruierten Kraftwerks kann sich nach dem Elektrizitätsbedarf des Versorgungsgebietes richten und mit diesem wachsen.

```
0005600010N001   IVK DIE                                    La
00056000200000   $00 GRO*S*.E                               taille
00056000300000   JS0 EINES                                  d'une
000560007*N001   $00 KRAFT.WERK.S                           centrale
00056000600000 5Z00 KONSTRUIER.                            construit
0005600040P004   P00 AUS                                   avec
000560005*P004   Y00 IHNEN                                 eux/elles
0V008000800000 4300 KO*NN                                  peut
0V008000900000   W00 SICH                                  se
0V008001500000 1130 RICHT                                  régler
0005600100P010   P00 NACH                                  vers/selon
00056001100000   I00 DEM                                   le
00056001200000   $00 BE.DARF ELEKTR.IZ.ITA*T.S              besoin d'électricit
00056001300000   I00 DES                                   du
000560014*P010   $00 GE.BIET.ES VER.SORG.UNG.S              domaine d'alimentat
00056001600000   M01 UND                                   et
.V008001900000 2130 WACHS                                  croitre
0005600170P017   P00 MIT                                   avec
000560018*P017   V00 DIESEM                                celui-ci
00056002000000       .                                     .
```

Eine dünne Schicht aus geschmolzenem Carbonat und inertem Füllmaterial liegt hier zwischen zwei Elektroden aus porösem Nickel.

```
0007200010N001   JS0 EINE                          Une
000720003*N001   $00 SCHICHT                       couche
00072000200000   Z00 DU*NN.E                      épais
0007200040P004   P00 AUS                          en/de
00072000600000   $00 CARBON.AT                    carbonate
00072000500000  2Z00 GE.SCHMOLZ.EN.EM             fondu
00072000700000   M0+ UND                          et
000720009*P004   $00 MATERIAL FU*LL.              matériau de remoliessage
00072000800000   Z00 INERT.EM                     inerte
.V0100010000000 2300 LIEG                        se trouve
00072001100000   A00 HIER                        ici
0007200120P012   P00 ZWISCHEN                    entre
00072001300000   C01 ZWEI                        deux
000720014*P012   $00 ELEKTRO.DE.N                 électrode
0007200150P015   P00 AUS                         en/de
000720017*P015   $00 NICKEL                       nickel
00072001600000   Z00 PORO*S.EM                   poreux
00072001800000       .                           .
```

Hier liegt momentan das entscheidende Problem, denn die ersten Zellen werden verhältnismäßig teuer sein, und der Preis wird nur in dem Maß sinken, in dem die Produktion wächst.

```
00085000100000   A00 HIER                              Ici
00085000300000   AZ0 MOMENT.AN                         momentanément
0008500040N004   IVK DAS                               le
000850006*N004   $00 PRO.BLEM                          problème
00085000500000  2Z00 ENT.SCHEID                       décisif
.V0020002000000 2300 LIEG                             se trouve
00085000700000   ,01 ,                                ,
00085000800000   M01 DENN                             car
0008500090N009   IOK DIE                              les
00085001000000   C02 ERST.EN                          premier
000850011*N009   $00 ZELL.EN                          cellule
0V0120012000000 3130 WERD
*V0120015000000 3100 SEIN                             seront
00085001300000   AZ0 VER.HA*LT.NIS.MA*S*.IG            en proportion
00085001400000   AZ0 TEUER                            cher
00085001600000   ,01 ,                                ,
00085001700000   M01 UND                              et
0008500180N018   IOK DER                              le
000850019*N018   $00 PREIS                            prix
0V0200022000000 3300 WIRD
*V0200025000000 2310 SINK                             baissera
00085002100000   A00 NUR                              seulement
0008500220P022   P00 IN                               dans/en
00085002300000   I00 DEM                              la
000850024*P022   $00 MAS*                             mesure
00085002600000   ,01 ,                                ,
0008500270R027   K01 IN                               dans/en
0008500280R028   K00 DEM                              lequel/laquelle
0008500290N029   IVK DIE                              la
000850030*N029   $00 PRO.DUKT.ION                      production
.V0310031*R028 2300 WACHS                             croit
```

Le système se compose de deux parties principales :

- L'analyse de la langue source
- La reconstruction de la langue cible

Ces deux parties ont un même fondement linguistique : **le système dérivationnel d'une langue**, d'une sous-famille ou d'une famille de langue. Nous allons examiner rapidement cet aspect, qui sera repris par la suite au cours de la présentation des différents principes.

3.2.2.3 Le système dérivationnel

Pour les nombreuses langues indo-européennes qui ont été examinées, la structure des mots est pratiquement identique. Tout est organisé autour d'une racine à laquelle on associe des préverbes, affixes, infixes et morphèmes grammaticaux. D. HERAULT cite LOMONOSOV, qui, à la demande de Catherine II de Russie, a utilisé cette notion pour créer à partir du français les mots qui manquaient à la langue russe de l'époque. Beaucoup de mots russes actuels sont par conséquent l'image exacte de mots français, sans qu'il s'agisse d'emprunts.

ex. : la racine PIS -> *écrire*
le préverbe PERE -> *une nouvelle fois*
le suffixe AT' est un des suffixes verbaux usuels
PERE.PIS.AT' -> *réécrire.*

Il n'y a ici aucune relation étymologique entre les éléments français et les éléments russes.
Les travaux effectués dans cette optique sur les langues européennes se sont raréfiés depuis 1950. Pourtant, si l'on se place au niveau des systèmes dérivationnels qui correspondent aux langues germaniques, romanes, slaves... on constate des propriétés importantes qui peuvent être exploitées par des systèmes informatiques :

- Les systèmes dérivationnels des langues évoquées plus haut ont à peu près les mêmes caractéristiques quantitatives.
- Au niveau d'un texte, tous les éléments du système apparaissent avec une régularité prévisible.
- Le système dérivationnel impose une classification du lexique, très différente de celle que l'on trouve dans les dictionnaires ordinaires.

Nous allons expliciter ceci dans les deux paragraphes ci-dessous.

3.2.2.3.1 Les propriétés quantitatives des systèmes dérivationnels

Si l'on se limite aux racines, préverbes, préfixes et suffixes, les résultats obtenus par D. HERAULT sont les suivants :

- Quelle que soit la langue, le nombre des racines importantes, celles qui donnent lieu à une dérivation non négligeable, se situe autour de 800, non compris les variantes (2 par racine en moyenne). Ce ne sont jamais des racines d'emprunt. On est donc amené à manipuler 1600 racines environ, qui correspondent à 75% des entrées d'un dictionnaire usuel (50 000 entrées). Le quart restant correspond à des mots isolés ou des dérivés de racines tombées en désuétude. Ces mots ne sont jamais des verbes et appartiennent le plus souvent au patrimoine artisanal, rural ou technique.

- Sur le plan sémantique, l'ensemble des racines principales couvrent à peu près le même univers pour chaque langue, avec des correspondances étymologiques fortes à l'intérieur des diverses familles, et faibles entre familles. Pour des raisons que nous rappelons dans 3.2.2.4., on ne peut pas parler d'un mais de deux systèmes dérivationnels pour l'anglais : le système germanique figé qui n'a plus d'activité dérivationnelle et le système roman, très voisin du système français.

- D. HERAULT distingue, en ce qui concerne la partie gauche de la racine, les préverbes et les préfixes. Les préverbes appartiennent à un ensemble fermé et s'associent fondamentalement aux racines de la langue. Leur action sémantique sur la racine est difficile à définir. Les préfixes relèvent d'une sémantique ouverte et modifient chaque racine de la même façon. Leur origine est souvent extérieure à la langue (grecque, latine). Ainsi, pour toutes les langues citées, les préfixes sont à peu près identiques. Les préverbes se distinguent par le phénomène d'assimilation, très faible dans les langues slaves et germaniques, forte dans les langues romanes. Il n'y a presque jamais plus de 3 préverbes devant la racine, l'assimilation est pratiquement nulle à leur niveau. En cas de non-assimilation, il y a entre 80 et 150 groupes préverbaux, dans le cas contraire, il y en a environ 250[1].

Il est extrêmement difficile d'attribuer un sens précis à un préverbe ou un groupe de préverbes, qui fonctionnent de façon variable sur des racines distinctes. Par contre, ils ont en commun de permettre pour chaque langue, de construire des bases de sens identique (la base est une association d'un ou de plusieurs préverbes à une racine, et le sens de cette association apparaît clairement). Le fondement du système des bases est composé d'environ 2500 éléments. A partir de ce niveau, tous les systèmes de bases sont sémantiquement équivalents, tout en présentant parfois des structures largement différentes.

- Les suffixes apparaissent dans une grande variété d'éléments (250), pour chaque langue. Ils jouent un rôle sémantique déterminé. Les suffixes peuvent être classsés par rapport aux catégories syntaxiques (verbal, nominal, adjectival, adverbial...). On peut alors établir une assez bonne correspondance de langue à langue. On constate que certains suffixes fonctionnent de façon "automatique". On peut les associer à une base quelconque pour obtenir un mot attesté, un mot qui n'existe pas encore ou un mot inconnu mais compréhensible[2]. La maîtrise du système des racines et des bases (bases purement verbales, purement nominales, irrégulières) conduit à l'exemple :

Racine : TRAC
Bases : TRAC, SOUSTRAC, ABSTRAC et EXTRAC

TRAC est une base régulière et verbale, on crée automatiquement TRACER, TRACEUR, TRACABLE , TRACTION, TRACTEUR.

SOUSTRAC, ABSTRAC et EXTRAC sont des bases nominales et représentent les bases verbales (SOUSTRAI, ABSTRAI et EXTRAI). On peut créer :

- SOUSTRACTION, SOUSTRACTEUR, SOUSTRACTABLE
- ABSTRACTION, ABSTRACTEUR, ABSTRACTABLE

---

(1) Pour le russe et le bulgare, le nombre des préverbes de base est faible, moins d'une vingtaine. Le nombre des groupes préverbaux est donc d'au plus 80. Le français et l'italien sont à l'opposé et ont un nombre important de groupes lié à une forte assimilation (AB.SIMIL -> AS.SIMIL).

(2) Nous pensons, en français à *-able/-ible* au niveau adjectival, *-er* au niveau verbal, *-eur/-teur et -ion/-tion/-ation/-ition* au niveau nominal.

- EXTRACTION, EXTRACTEUR, EXTRACTABLE

On aboutit à des mots inexistants mais compréhensibles.

3.2.2.3.2 La classification du lexique

Les mots sont ordinairement classés par ordre alphabétique, avec une marque syntaxique (verbe, nom, adjectif...). Cette classification n'est pas satisfaisante si l'on part du principe que tout tourne autour des propriétés dérivationnelles de la racine ou de la base. Le système repose sur une autre classification et distingue:
- Pour chaque langue, une classe importante de *"mots -outils"* (prépositions, conjonctions, certains adverbes, déterminants, ...). Cette classe contient environ 500 éléments, dont certains sont ambigus.
- Les *"mots-objets"*, en dehors ou presque du système dérivationnel. Ils représentent réellement des objets (*arbre, feuille...*), peuvent provenir d'êtres vivants (*aile, écaille...*) ou sont construits par l'homme (*chaise, table...*). Pour passer d'une langue à l'autre, il faudra, dans ce cas, adopter la méthode lexicale classique. Cela correspond à environ 3000 entrées. Beaucoup de ces mots ont un caractère international (médecine, biologie, physique...).
- Des *"mots-exceptionnels"*, normalement dérivés, mais qui sont devenus des *"mots-objets"* pour des raisons extra-linguistiques (réaction, éprouvette, ensemble, fonction..). Ces mots ne seront exceptionnels que par rapport à un domaine donné.
- Les *"mots-foncteurs"* (genre, classe, espèce, famille, type, modèle...) indiquent souvent un pluriel indéfini, dans une situation déterminée. Ils ne sont pas plus de 30 mais il est intéressant de les connaître dans le sens où leur rôle sémantique est pratiquement nul.
- Les *"mots-dérivationnels"*. Pour les analyser, il faut les décomposer, isoler la racine, les préverbes, préfixes, suffixes, morphèmes grammaticaux et reconstruire la base. Il faudra ensuite connaître les caractéristiques de la base.

Avant de voir comment cette classification sera utilisée, nous évoquerons le problème essentiel qu'elle pose et que nous devrons résoudre : de nombreuses langues contiennent énormément de mots d'emprunt. Il faut donc construire un système de sélection, qui devra associer chaque mot dérivationnel à son système, que ce soit celui de la langue ou un système d'emprunt.

3.2.2.3.3 La sélection entre plusieurs systèmes dérivationnels

Pour quelles langues la sélection s'impose-t-elle ? Dans les langues germaniques, la sélection germanique/roman est essentielle. Dans quelques langues slaves, le russe et le bulgare par exemple, il en va de même. Pour le tchèque, une sélection slave/roman/germanique s'impose. Dans les langues romanes, aucune sélection n'est indispensable (ce que nous appelons système dérivationnel roman contenant une partie grecque importante). En guise d'exemple et pour en souligner l'inutilité, citons *"barycentre"* (grec *bary* : lourd, latin *centre* d'origine grecque) ou *"anormal"* (*a-* grec privatif et un dérivé de *norm* purement latin : angle, équerre). Notons qu'il faudra distinguer ce *a-* privatif du *a-* de *abaisser*, distinction que permettront certaines carctéristiques de la racine ABAISS-.
On peut se demander s'il est possible, pour l'allemand, de "désenchevêtrer" les deux systèmes, d'une façon automatique, c'est à dire, sans intervention humaine. Nous verrons que c'est possible à 100% dans 4.3.2.5.3 et 4.3.2.5.4. On peut dès maintenant ajouter quelques commentaires. On constate que deux systèmes dérivationnels distincts présentent très peu de racines homographes (russe PRAV : *droit* et français PRAV : *mauvais* dans *dépravé*, allemand STAB : *bâton* et français STAB : *stable*).

La sélection de ces racines et des autres est fondée sur le fait que les systèmes préverbaux sont presque toujours complétement disjoints (IN et AB sont communs pour le français et l'allemand), et qu'il en est de même pour le système suffixal.

Ces constatations ne conduisent pas à une conclusion, il faudrait un travail colossal pour y parvenir, mais à l'hypothèse selon laquelle les systèmes dérivationnels d'une même famille de langues (ici indo-européennes) sont "conçus" de telle sorte qu'ils peuvent cohabiter les uns avec les autres, sans que soient créées de nombreuses ambiguïtés.

3.2.2.4 La compréhension et sa localisation

Avant de parler du transfert, nous allons préciser à quels endroits se trouvent les éléments indispensables à la compréhension du texte.

De façon très globale, un texte est en fait la superposition de deux structures : les "mots-objets" et "mots-exceptionnels" d'une part, les "mots dérivationnels" (plutôt associés à des racines verbales) d'autre part. La première partie permet de savoir de quoi on parle, la seconde partie comment on en parle.

La sélection joue un rôle important dans la localisation des "mots-objets". En allemand par exemple, la mise en évidence des mots romans simplifie le travail de compréhension. Ces mots sont souvent internationaux et n'ont besoin d'aucune interprétation. Ces mots restent nominaux et ont par conséquent peu ou pas d'influence verbale. Cette sélection est insuffisante pour savoir ce dont on parle. Il est indispensable de disposer d'un analyseur syntaxique pour mettre en évidence les syntagmes nominaux, prépositionnels ou non. Il sera décrit pour l'allemand en 4.3.3.

Ces syntagmes nominaux sont reliés les uns aux autres, par des syntagmes verbaux de deux types :

- les syntagmes verbaux "hypersyntaxiques" comme *nous allons voir, nous allons examiner...*
- les syntagmes verbaux d'action qui agissent sur les objets du texte. Ces syntagmes verbaux peuvent prendre un aspect nominal, éventuellement, comme dans un titre Dans l'exemple "*Méthodes techniques de construction des barrages hydro-électriques*", le syntagme verbal est représenté par *CONSTRUCTion* et agit sur "*...barrages...*", tandis que *"Méthodes (techniques)"* est un simple mot foncteur.

3.2.2.5 Le tranfert "global"

Passer de la LS à la LC, c'est tranférer les informations recueillies dans LS vers son image simplifiée dans LC. Habituellement, le transfert s'effectue par petites unités et s'oppose à une analyse globale, complète et profonde du texte en LS.

Le principe de **globalité du transfert** signifie que pour passer de LS à LC, il s'effectue en une seule fois, dès que l'analyse du texte en LS est terminée (l'analyse est conduite aussi loin qu'il est possible et raisonnable d'aller).

On retrouve dans le schéma du système, les trois étapes suivantes :

- Analyse du texte LS privilégiant la compréhension
- Transfert global de LS vers LC
- Génération du texte LC

Ces trois étapes appellent trois questions :

1. *Comment privilégier la compréhension ?* : L'analyse se résume couramment à l'analyse morphologique et syntaxique de chaque mot avec une segmentation de la phrase. Quel que soit son degré de perfectionnement, cette analyse ne donne pas une idée sur le contenu du texte et n'a qu'une relation lointaine avec la compréhension. Pour comprendre, il semble préférable d'agir en sens inverse, en n'accordant à la morphologie et à la syntaxe qu'un rôle secondaire. Ce ne sont pas les mots qui sont des unités de raisonnement, mais l'ensemble des éléments qui constituent le système dérivationnel de LS (racines, préverbes, affixes). Cela correspond au système de formation des mots de LS. Le noyau de ce système est constitué par une partie qui regroupe les "racines verbales", celles qui donnent l'idée d'une action, d'un processus.

TABL, CHAIS, POUTR, POIT : Ces mots sont inertes

CÉDer, sucCÉDer, déCÉDer, proCÉDer... :
CESSion, sucCESSion, proCESSion, sucCÈS, déCÈS, proCÈS

Pour les mots suivants, le sens apparaît dès lors que l'on connaît la racine et le 1er préverbe. Ce groupe est une véritable unité sémantique. Nous l'appellerons base.

CÉD/CESS, SUCCÉD/SUCCESS,/SUCCÈS, CONCÉD/CONCESS sont trois bases avec les variantes.

inSUCCÈS ou rétroCESSion ont SUCCÈS et CESS pour base.

Cette partie, remarquablement organisée dans toute langue, jouera le rôle central dans notre analyse et privilégiera de ce fait la compréhension. Ainsi le système ne fera pas de distinction entre *concéder* conjugué et *concession*, quelle que soit pratiquement la situation syntaxique.

Il faut que soit concédé...
Il faut que l'on obtienne la concession...
Il est nécessaire que l'on obtienne la concession...
Il faut que soit obtenue la concession...

2. *Que va-t-on tranférer ?* : Ce sont toutes les bases qui seront rencontrées, avec ce qui les entoure (préfixes, suffixes). On transmet également la liste des "mots inertes" sur laquelle sera effectué un travail préliminaire.

3. *La génération du texte LC ?* : Il faut distinguer deux étapes distinctes :

- Il faudra d'abord assurer une correspondance convenable entre les systèmes dérivationnels de sorte qu'à une base de la langue source supportant un certain type de dérivation soit associée une base de la langue cible, ayant à peu près le même niveau d'ambiguïté que la base de langue source et dont le type de dérivation sera connu, en vertu des règles de correspondance des deux systèmes.

Allemand	**Français**
LEIT	CONDUIR/CONDUCT
LEITen	CONDUIRe
LEITer (der)	CONDUCTeur

LEITer (die)	l'origine est différente (lehnen). Mais la racine commune a ici la forme *klei* apparentée à κλινειν (Klinik, Klimat...) et au latin *clinare* (deklinieren, Klient...), (incliner...).
LEITung	*CONDUCTion une contrainte devrait donner CONDUITe REDUIR/REDUCT sans contrainte donnera REDUCTion

Ce simple exemple montre que la correspondance des systèmes dérivationnels est une partie complexe du transfert.

- Les phrases en langue cible doivent être construites selon le schéma de l'analyse du texte source. Cette construction touche à la notion de correspondance de surface que nous évoquerons en 3.2.2.7. Avant de parler de la correspondance de surface et de l'analyse superficielle, il convient de préciser ici notre approche des dictionnaires.

3.2.2.6 L'absence de dictionnaire

Qu'il s'agisse de l'analyse du texte source, de la génération du texte cible ou du transfert global, le système opère sans dictionnaire, au sens traditionnel du terme. Nous allons prendre l'exemple de l'automate allemand-français pour indiquer les informations lexicales dont il a besoin.

- Maîtrise complète des systèmes dérivationnels de l'allemand, du français , ainsi que du roman germanisé (système roman très proche du français intégrant les modifications orthographiques consécutives à son implantation en allemand). Les trois systèmes sont voisins d'un point de vue quantitatif (1500 racines avec 2500 variantes, 150 préverbes et 250 suffixes approximativement). Il est difficile de dire à combien d'entrées du dictionnaire cela correspond (à 15 000-20 000 entrées), en langue source, sans compter les entrées qui existent potentiellement, mais ne sont pas usuelles (ex. : *PARable* opposé à *inPARable)* et seront engendrées par le système en langue cible.

Les systèmes dérivationnels ne permettent pas de dominer la totalité des deux langues.
- Il faut ajouter une liste des mots outils (articles, prépositions, conjonction...). On compte environ 500 éléments.

- Les mots restants sont les mots "inertes". Leur quantité varie selon le type de texte. Ils appartiennent à un ensemble très ouvert. Dans le cas précis de notre exemple, un sélecteur roman/germanique doit indiquer si un mot inerte donné est d'origine romane ou non. En effet, s'il est d'origine romane, le transfert dans la langue cible se fait sans modification. Ces mots sont très nombreux dans le discours scientifique. Il reste un noyau que l'on ne peut pas atteindre, de petite taille pour chaque texte. C'est à ce noyau que correspondra le seul vrai dictionnaire du système. Contenant également les mots inertes romans qui n'auront pas été reconnus, il constitue la limite du principe de l'absence de dictionnaire. C'est la qualité du sélecteur qui détermine l'importance réelle et théorique de ce noyau, l'existence du sélecteur dépendant des groupes de langues traités.

3.2.2.7 Analyse de surface

L'analyse complète du texte source est limitée à l'analyse de surface. Elle reproduit informatiquement l'analyse traditionnelle enseignée dans les établissements de l'enseignement secondaire. Pour les langues que nous traitons, il s'agit de :

- repérer le verbe avec précision

- reconstituer le groupe verbal

- trouver les compléments prépositionnels obligatoires (*se méfier de, se souvenir de...*)

- localiser les autres compléments prépositionnels

- déduire les syntagmes nominaux sujet et complément direct

- segmenter la phrase

Il nous faut introduire deux nouvelles notions, **le module hypersémantique** qui facilitera grandement la détermination des syntagmes nominaux sujet, complément direct et complément prépositionnels et **le module hypersyntaxique** qui sera d'une aide précieuse dans la segmentation de la phrase.

Nous obtenons ainsi une description simple de la phrase, facilement transférable vers une autre langue, sans aucun formalisme. C'est là un point fondamental qui tranche avec ce qui a été l'objet du chapitre I et rappelle les termes de sa conclusion.

3.2.2.8 Le principe des groupes

Il nous semble impossible d'imaginer que l'on pourra construire des systèmes universels où les langues n'apparaîtront que comme données. Il est peu raisonnable, a contrario, de construire des systèmes capables de ne travailler que sur un couple de langues déterminé.

Nous empruntons une voie moyenne et raisonnons sur des groupes de langues, en distinguant :

- le groupe germanique (allemand, néerlandais et sous-groupe scandinave)
- le groupe anglais (anglais)
- le groupe slave (sous-groupe bulgare, autres langues)
- le japonais
- l'indonésien
- l'arabe

Il est toujours possible de raisonner en terme de groupes, encore faut-il en monter l'intérêt pratique.

Pourquoi le groupe de langues, dans son organisation traditionnelle, constitue-t-il la meilleure unité de raisonnement en Traitement Automatique des Langues Naturelles ?

Les nombreuses langues qui ont été examinées, disposent d'un système dérivationnel autonome et d'un système d'adoption des mots étrangers. Pour des raisons historiques, **D. HERAULT** rappelle qu'il n'en est rien pour l'anglais. Le conflit qui a opposé le système germanique (saxon) au système roman (normand) a entraîné leur défaite. Le système germanique s'est figé dans la situation du XV^{e} siècle environ et n'a procédé depuis lors à aucune création de mots. Le système roman, n'a pas évolué énormément et s'est contenté de recueillir des mots français et italiens, à partir de la Renaissance. La partie romane de la langue anglaise, en d'autres termes, suit strictement l'évolution des systèmes dérivationnels des langues romanes, sans procéder à des créations. La langue anglaise n'a donc pas le même comportement que les autres langues indo-européennes occidentales. Il est très difficile de raisonner sémantiquement avec elle. L'anglais, apparemment simple, est en fait très complexe.

3.2.2.9 Hyperanalyse, hypersémantique et hypersyntaxe

Dans le paragraphe 3.2.2.7, nous avons évoqué le recours aux module hypersémantique et hypersyntaxique pour la détermination des syntagmes nominaux essentiels à la compréhension et le repérage des schémas d'enchaînement de phrases du type raisonnement, définition...

Pourquoi hyperanalyse ? Parce que ce ne sont ni le mot, ni la phrase qui font office d'unité principale. Ce sont de grandes portions de texte, et à la limite, le texte entier. L'hyperanalyse consiste donc à tenir compte de tout ce qui se passe dans le texte et s'efforce de ne jamais traiter une phrase indépendamment de celles qui l'ont précédée.

Comment est-ce possible ? On ne peut pas utiliser ici le système dérivationnel, qui, par sa nature prédicative, verbale, apparaît normalement dans toute phrase ou groupe de phrases et apporte les indications principales sur son ossature (syntaxe). On ne possède en fait pratiquement aucune information sur l'ensemble des syntagmes nominaux qui représentent ce dont on parle, ainsi que sur leur cohérence. Le système dérivationnel permet juste de déterminer la façon dont on en parle. C'est là qu'intervient le module hypersémantique.

3.2.2.9.1 Le module hypersémantique[1]

Il sélectionne les "objets spécifiques" du texte (objets véritables du texte) et les "objets standard", c'est à dire les objets que l'auteur utilise sans les définir, car il pense que ses lecteurs les connaissent parfaitement. Ces objets extraits (syntagmes nominaux parfois complexes), on les suit dans le texte, tels qu'ils ont été repérés, ou plus ou moins modifiés, *une fonction continue* donnant par exemple *une fonction uniformément continue*.
A priori, rien ne les distingue d'un point de vue linguistique. Pour accéder à ces unités sans faire appel au système des mots-clés ou à des systèmes analogues qui sont extérieurs au texte, on a recours à une méthode extra-linguistique. On aborde le traitement sans d'autre information que l'équivalence informatique d'un texte et de sa richesse typographique. Nous allons donc analyser sa typographie, partant du principe qu'une partie de l'information réside dans les moyens utilisés par l'auteur pour attirer l'attention du lecteur : hiérarchie des titres et sous-titres, paragraphes marqués par une lettre puce, modification des fontes, des polices, des corps, des chasses et des styles.

De même qu'il sera d'un accès difficile pour le lecteur humain, un texte sans marques typographiques se prêtera peu à ce genre d'analyse. Il faut noter à propos des textes informatisés que les marques de typographie sont absentes ou cachées. Elles correspondent en effet à des codes insérés dans le texte ou stockés en fin de fichier. Ils indiquent aux périphériques de sortie (écran ou imprimante) qu'une chaîne de caractères doit subir telle modification. C'est la raison pour laquelle nous avons codé les textes d'essai (4.3.1) en clair, pour restituer la présentation du texte source et utiliser ces particularités.
Le programme localise automatiquement tous les fragments mis en relief, en distinguant le texte, les titres, les sous-titres, les annotations, les légendes, les notes de bas de page... L'analyse de ces fragments permet de saisir de nombreux syntagmes nominaux qui deviennent alors des objets spécifiques potentiels (OSP).

---

(1) Dans "Analyse automatique du Tchèque. Définition d'un module prédicatif général", Thèse d'Etat, Paris, 1979, P. POGNAN parle de module notionnel (p. 298).

Ils sont ensuite confrontés à la totalité du texte par un procédé d'hybridation et un procédé d'épuration[1]. Après avoir débarrassé le fichier des expressions en double, on procède à une hybridation, sans aucune référence au texte. Si l'on obtient par exemple les expressions *A de B* et *B de X*, on crée *AB de X* et *BA de X*. Cela permet d'associer les adjectifs aux substantifs et d'engendrer d'autres objets spécifiques potentiels. On obtient ainsi trop d'objets spécifiques potentiels dont certains sont sémantiquement inacceptables. Lors d'une phase d'épuration, on vérifiera alors sur le texte ou une partie du texte la présence ou l'absence des expressions obtenues, ce qui nous permet de travailler sur un plan discursif avec d'autres critères que les marques typographiques. Ces syntagmes nominaux-objets spécifiques ont une très forte probalité de se retrouver dans le texte. Ils sont alors remis dans l'ossature prédicative, ce qui permet de vérifier la compatibilité entre cette ossature et les objets spécifiques (*"la façon dont on parle"*, l'ossature, doit correspondre à *"ce dont on parle"*).

3.2.2.9.2 Le module hypersyntaxique

Il est composé de deux parties qui correspondent à l'hypersyntaxe locale et à l'hypersyntaxe globale.

3.2.2.9.2.1 Hypersyntaxe locale

Il s'agit de localiser :

- tout ce qui, à propos d'un objet, permet de l'introduire, de le définir, de le nommer

- tout ce qui correspond à une déduction, une remarque, une conclusion, un renvoi...

Les membres de phrase qui remplissent ces fonctions sont peu nombreux et sont étroitement liés, par leur structure, au système dérivationnel, dont on sait qu'il est essentiellement prédicatif puisque fondé sur des racines qui représentent des actions. On ne retrouvera ce type de phrases spécifiques qu'au niveau hypersyntaxique local. La maîtrise des opérations hypersyntaxiques locales permet de mieux situer la localisation des syntagmes nominaux-objets, et même, dans certains cas, de les extraire.

Soit la phrase type : "*On appelle suite numérique convergente toute suite qui...*". Le schéma est : On appelle XY avec Y commençant par un délimiteur indéfini.

Dans ce schéma, X (*suite numérique convergente*) est automatiquement extrait, et l'on sait simultanément que le membre Y contient la définition de l'objet X. Les situations ne sont pas toujours aussi simples mais la combinaison avec les techniques de repérage typographique donne d'excellents résultats.

3.2.2.9.2.2 Hypersyntaxe globale

Dans certains textes à volonté didactique affirmée, des schémas de paragraphe se répètent, à quelques variantes près. Ces paragraphes sont en général consacrés à des raisonnements, des déductions, des descriptions d'expérience, des définitions...

---

(1) Ce module a été réalisé pour le français par J.-P. HUBAC. Il est décrit dans D.HERAULT : *Compréhension automatique et spectre sémantique*, Editions J. Favard, Paris, 1981, pp. 112-116

L'examen de ces schémas, qui varie peu d'une langue à l'autre, conduit à penser que l'on peut, par ce biais, accéder à la connaissance de l'architecture de pans entiers et en général, importants. Ces schémas hypersyntaxiques globaux, largement indépendants du sujet abordé, permettront peut-être d'envisager un transfert d'architecture, de langue à langue.

Nous allons maintenant montrer à quoi ressemble un logiciel qui effectue toutes ces opérations, avec la description du système d'interprétation automatique des langues germaniques. Nous en donnerons les caractéristiques (3.3.1), justifierons le choix des langues (3.3.2), résumerons (3.3.3) les modules de la première partie (ANALYSE) détaillés dans le chapitre IV, puis ébaucherons ce que devrait être la seconde partie (TRANSFERT) en définissant ses propriétés (3.3.4).

3.3 Le Système d'interprétation automatique des langues germaniques

3.3.1 Caractéristiques générales

Il s'agit d'un logiciel de grande taille (25 000 lignes dans sa version définitive), écrit en PL/I Optimizer[1]. Le choix de ce langage doit beaucoup à sa maniabilité et à ses performances dans la manipulation des chaînes de caractères, tout comme au cadre des recherches (Centre de calcul du CNRS à Orsay) et aux ordinateurs utilisés au début des travaux. Une actualisation des travaux effectués, pour tirer un avantage des méthodes employées et justifier l'approche retenue, exigerait un passage à un autre langage de programmation. Nous pensons au langage C, pour sa souplesse et sa transportabilité et au système d'exploitation UNIX qui permettrait de s'affranchir des gros calculateurs. Le logiciel a la structure d'ensemble suivante:

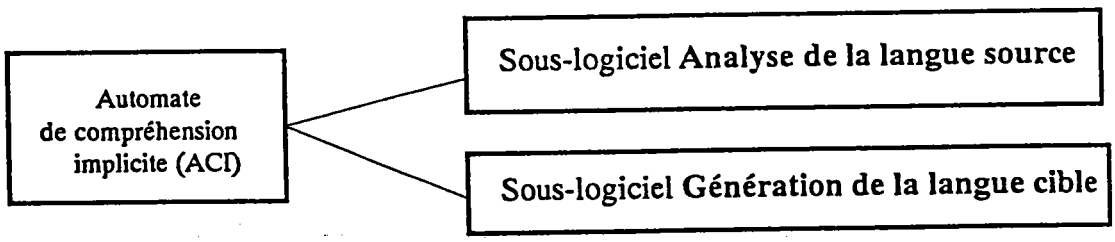

Chaque sous-logiciel est divisé en *modules*, chaque module est constitué de *programmes*. Chaque programme ne dépasse pas 200 lignes. La description que nous allons proposer concernera le logiciel allemand-français. Néanmoins, le chapitre IV présentera des résultats sur l'anglais, le luxembourgeois et le néerlandais, pour le module verbal (4.3.2.2) et le module mots-composés (4.3.2.5).

3.3.2 Langues sources germaniques

Comme nous l'avons indiqué en 3.2.2.6 le système n'utilise pas de dictionnaires bilingues traditionnels. Les langues germaniques ont été retenues pour étayer les raisons de ce choix. En effet, ces langues ont la propriété de permettre à leurs utilisateurs de composer les mots entre eux, de créer des mots composés.

---

(1) Un avantage du pl/1 : la possibilité de compiler les programmes et de les manipuler sous forme de modules chargeables, très rapides.

Ces mots sont par définition en nombre infini. Aucun dictionnaire ne peut les répertorier. Les systèmes de traitement automatique ont par conséquent beaucoup de mal à traiter ces mots composés, si ce n'est en sémantique très fermée, ce qui est d'autant plus regrettable que ce sont en général des "mots-objets" de la plus grande importance sémantique, puisque l'auteur du texte a pris un soin particulier à les créer.

C'est au prix d'un module très complexe et de grande taille que nous pouvons localiser tous les mots-composés d'un texte allemand, sans dictionnaire, et les décomposer en segments, chaque segment étant lui-même décomposé morphématiquement. Les données utilisées se résument à des tables de racines et d'affixes, ce qui permet, en raison d'un encombrement réduit, de travailler en mémoire centrale[1].

3.3.3 Le sous-logiciel *"ANALYSE DE LA LANGUE SOURCE"*

- Un module initial qui met le texte en forme pour le travail à effectuer (900 lignes).

- Le premier module concerne les verbes. Quelle que soit la langue, la première partie de l'analyse concerne le verbe. Il est d'une importance capitale pour le reste des opérations (900 lignes).

- Le module "mots-composés" lui succède. Il est formé de quatre sous-modules (analyse générale, décomposition morphématique du lexique des mots/segments obtenus, segmentation par cohérence interne (dans le contexte du texte complet), et recherche des mots-composés verbaux (8000 lignes).

- L'analyseur syntaxique regroupe une quarantaine de programmes (6500 lignes).

Pour notre texte d'essai (3500 mot, 149 phrases), l'analyse complète a été effectuée en moins d'une minute sur le NAS 8090 du CNRS. Ce chiffre n'a cependant aucun sens, dès l'instant où il dépend du langage de programmation et de la puissance de calcul de l'ordinateur utilisé. Il fournit cependant un ordre d'idée sur l'efficacité de structure modulaire[2].

3.3.3.1 Le module verbal

Composé de quatres programmes principaux, il traite

- les verbes d'emprunts (*-ieren*)
- les verbes irréguliers
- les verbes réguliers
- la désambiguïsation de ZU

Un programme initial filtre et élimine les mots qui ne peuvent pas être des verbes ("mots-outils" et mots commençant par une majuscule). Son efficacité sera réduite pour les autres langues (absence de la majuscule du substantif).

En sortie, on associe au verbe sa base et un code qui précise sa situation (conjugaison et ambiguïtés). Une présentation particulière des données simplifie la tâche des programmes (1800 racines verbales et quelques bases pour traiter correctement le "GE").

---

(1) Les temps d'accès s'expriment en nanoseconde alors que sur une mémoire de masse (disquette, bande, disque dur), ils s'expriment en milliseconde.

(2) Il est en effet possible de faire tourner deux modules en même temps si leurs objectifs le permettent. L'architecture des appareils qui autorisent un fonctionnement "multitâche" est alors d'un grand avantage.

L'analyse est donc menée aussi loin qu'il est possible de la mener. C'est l'analyseur syntaxique qui lèvera la plupart des ambiguïtés mises en évidence.

3.3.3.2 Le module "mots-composés"

Les quatre sous-modules sont :

3.3.3.2.1 Le sous-module "Analyse générale"

Indépendamment de tout texte, il segmente les mots à tiret, localise des foncteurs-avant et des foncteurs-arrière (la liste est subjective, ils correspondent à des éléments autonomes fonctionnant souvent en suffixation). Il traite ensuite les positions du "ß", certaines chaînes (-HEITS, -KEITS, -SCHAFTS, -UNGS...) et surtout les paires et triades de segmentation (nous avons montré[1] que la jonction entre deux mots ou entre une racine et un groupe préfixal ou suffixal n'était possible que dans la mesure où la paire/triade de jonction était "anormale", c'est à dire, ne se trouvait pas à l'intérieur d'un mot non-composé. Toutes les jonctions ne présentent pas de telles caractéristiques (nous utilisons 400 chaînes). L'algorithme est le suivant : Si dans un mot ou segment, une paire ou une triade est repérée, on doit vérifier s'il ne s'agit pas de la jonction de la racine avec sa partie avant (jusqu'à 3 préverbes) ou sa partie arrière (nombre quelconque de suffixes). Après vérification, on peut segmenter. Le système est récursif, il s'applique aux segments obtenus et ainsi de suite. La méthode est très rapide mais ne localise que 75% des composés.

3.3.3.2.2 Le sous-module "Décomposition Morphématique"

Une dizaine de programmes recherchent successivement les mots germaniques, puis les mots dérivant du système dérivationnel roman et orthographiés germaniquement. Par mot, on entend les mots simples, les mots composés non encore localisés et les segments des mots composés partiellement ou totalement décomposés. Ces programmes sont capables d'analyser correctement les racines romanes et germaniques homographes. Les résultats obtenus sont intéressants : les mots ou segments qui ne sont ni germaniques ni romans sont, soit des noms propres, soit des mots composés. On peut donc aboutir, dorénavant à une localisation intégrale des composés. A ce stade, il ne s'agit que de localisation sans décomposition.

3.3.3.2.3 Le sous-module "Segmentation par Cohérence Textuelle"

On peut imaginer qu'un texte non-littéraire est cohérent dans son développement et que cette cohérence se retrouve au niveau des mots composés. On va donc tester cette hypothèse en recherchant la présence des segments déjà obtenus dans les mots que le sous-module précédent a relevés comme potentiellement composés. La présence est testée par la droite, sans la moindre lemmatisation, puis par la gauche et finalement, si cela est possible, centralement. Cette technique améliore de 20% les résultats obtenus par le premier sous-module. Il faut indiquer que sans la décomposition morphématique sélective, on n'obtiendrait peu de résultats.

A ce stade des résultats partiels sur le texte d'essai ("Des centrales électriques à piles à combustible"), les mots composés localisés mais non segmentés sont : *Baustein, Kohlestäbe, Notstromaggregate, Überlandleitung, Zeiteinheit, höhersiedenden, Lastabhängig, raumsparend, umweltschonenden, wagemutige et Wasserstoff.* Ce dernier mot est

---

(1) **P. DIMON : "Aspects de la composition dans les langues germaniques et réalisation d'un algorithme de localisation des composés pour l'allemand", *Thèse de 3ème cycle*, Paris III, 1978**

un segment intérieur sur lequel le foncteur *-stoff* n'a pu être mis en évidence. Les mots soulignés sont des formes verbales qui seront traitées par le sous-module suivant.

3.3.3.2.4 Le sous-module "Mots composés verbaux"

Les mots composés verbaux se retrouvent sous forme de participes présents ou passés, décliné ou non. Il n'y a jamais plus de deux segments, le second étant précisément le verbe, qui, dans la majorité des cas, n'est pas un verbe d'emprunt. A partir de ces hypothèses, on construit le sous-module en utilisant les programmes de décomposition-sélection et les programmes verbaux.

3.3.3.3 Le module "Analyseur syntaxique"

L'analyse est linéaire, sans invoquer le moindre arbre. Elle découpe chaque phrase en propositions (coordonnées, subordonnées) et les propositions en syntagmes verbaux et nominaux. C'est une analyse "logique" classique. Pour aboutir à ce résultat, chaque mot d'une phrase donnée est codé de sorte que l'on puisse circuler très facilement dans la phrase, dans les deux sens, afin que certains ensembles soient constitués (propositions, syntagmes) en respectant leur hiérarchie.

- programme "LIAISON" : repérage de certains groupes, indispensables par la suite (als daß, so daß, bis zu, ohne daß...)

- programme "VIRGUL1" : repérage des virgules délimiteurs, c'est à dire des virgules qui limitent les syntagmes nominaux et a fortiori, les propositions. Les virgules de liaison à l'intérieur d'un syntagme nominal sont strictement exclues.

- programme "COORDIN" : repérage des conjonctions-délimiteurs (aber, denn, oder, sondern, und...).

- programme "VIRGUL2" : certaines virgules, compte tenu de ce qui précède, deviennent délimiteurs.

- programme "PARSEP1" : repérage des particules séparables (sauf *ein*)..

- programme "ZUINF" : repérage de ZU particule qui, presque toujours, précède une forme infinitive. Ce repérage permet d'éliminer beaucoup d'ambiguïtés verbales.

- programme "RELAT1" : traitement des pronoms relatifs non ambigus (*denen, deren, dessen, was, wo, wobei...*). Pour les propositions concernées, il met en évidence le syntagme verbal associé.

- programme "RELAT2" : premier filtre des pronoms relatifs identiques à l'article défini.

- programme "RELAT3" : second filtre qui, lui, s'intègre au système verbal éventuellement associé, lequel doit avoir certaines propriétés pour qu'il s'agisse réellement d'un pronom relatif.

- programme "VIRGUL3" : adjonction de virgules délimiteurs, à la clôture des propositions relatives

- programme "RELAT4" : rôle de nettoyage en tenant compte de la position des virgules délimiteurs

- programme "ZUCOMP" : mise en évidence des liaisons entre UM, OHNE, STATT, ANSTATT et d'autre part ZU-infinitif.

- programme "CONJC1" : premier filtre pour les conjonctions de subordination, *(da, bevor, ehe, indem...)*.

- programme "CONJ2" : second filtre traitant certaines conjonctions ambiguës en adverbe ou en proposition *(als, da, damit, seit, bis, während)*

- programme "PROSUB" : mise en évidence de la limite finale droite des propositions subordonnées non-relatives.

- programmes "G/ALS1" et "G/ALS2" : Ils délimitent à droite les "groupes-als" (*als=comme, en tant que*).

- programmes "ZU" : détermine des "ZU-quantité" (*zu=trop*), parmi les ZU qui ne sont pas des "ZU-infinitifs".

- programmes "GP1" à "GP5" : ils déterminent les groupes prépositionnels, avec une méthode voisine de celle des "groupes-ALS", mais plus complexe.

- programme "EIN" : examen de tous les EIN (article indéfini, particule séparable) et détermine les véritables particules séparables.

- programme "PARSEP2" : localisations des particules séparables "internes" (en d'autres termes, celles qui ne sont pas rejetées en fin de proposition).

- programmes "SNDIS1" à "SNDIS5" : déterminent les syntagmes nominaux disjoints, c'est à dire les syntagmes nominaux qui contiennent un ou plusieurs groupes prépositionnels.

- programmes "SNCON1" à "SNCON3" : déterminent les syntagmes nominaux connexes.

A ce niveau de l'analyse, tous les éléments des propositions ont été déterminés, sauf certains adverbes ou des adjectifs attributs. Il reste donc à reconstituer les syntagmes verbaux des propositions principales ou indépendantes.

- programmes "SV1" à "SV3" : reconstitution des syntagmes verbaux avec élimination des dernières ambiguïtés.

Tout ce qui pouvait être réalisé au niveau de l'analyse du texte source a été fait. L'ensemble des renseignements indispensables pour la réalisation du transfert sont désormais disponibles.

3.3.4 Le sous-logiciel *"GENERATION DE LA LANGUE CIBLE"*

Le second sous-logiciel a pour mission générale d'écrire, par transfert, le texte cible. Pour cela, on utilise de façon constante et soutenue, la correspondance entre les systèmes dérivationnels, afin de créer les mots ou segments de mots compréhensibles.

3.3.4.1 Le module d'interprétation des mots composés

C'est le module qui s'impose en premier. Dans sa première version, le système interprète de la droite vers la gauche, en mettant des "de" de liaison, sauf dans certains cas

de foncteur (comme *METER...* en allemand, qui devient *mètre* en français sans renversement de l'ordre des segments).

ex. : *Wechselspannung*
La décomposition donne WECHSEL/SPANNung et fait apparaître un mot composé avec les racines WECHSEL (CHANG) et SPANN (TEND).
Par dérivation automatique et propriété particulière WECHSEL donne CHANGement et SPANNung devient TENSion. L'inversion systématique donne le résultat :
Wechselspannung -> Tension (de) changement
Le mot n'est pas compréhensible hors-contexte, mais dans les textes où il apparaît (électricité, électronique) le lecteur spécialiste reconstruira plus ou moins facilement *tension alternative.*

ex. : *Spannbeton -> béton tendu*
Le résultat est ici obtenu grâce au sélecteur roman/germanique et sera rétabli par un spécialiste du génie civil par *béton précontraint.*

Il convient de rappeler que que dans un texte non-littéraire allemand, les mots composés occupent une place considérable, plus de 25% des occurrences le plus souvent. Par ailleurs, comme on l'a déjà indiqué, ils représentent la majeure partie des "mots-objets" du texte et permettent de savoir immédiatement ce dont parle le texte. On peut donc donner du texte, en dehors de toute analyse syntaxique, une image qu'un spécialiste du domaine pourra exploiter, ceci pour un coût très faible. Ceci est à l'origine d'un système de documentation automatique "dynamique" que nous souhaiterions mettre au point pour les avantages qu'il apporterait (non lié à un système de mots-clés).

3.3.4.2 Le module d'interprétation des syntagmes verbaux

Il devra respecter les conjugaisons, pour le mieux. Dans son état actuel, le système se borne à un transfert rudimentaire. Au présent correspond le présent, au prétérit correspond le passé composé, le futur engendre le futur. Certaines formes font apparaître un subjonctif ou un conditionnel. Pour les temps composés, la présence d'un auxiliaire entraîne la présence de l'auxiliaire normal du verbe français.

3.3.4.3 Le module d'interprétation des mots non composés

Cette interprétation dépend de la nature germanique ou romane. Un mot roman est pris tel quel, sans correction orthographique dans la version actuelle. Un mot germanique, suivant son analyse, implique une reconstruction en français, ou bien, étant un "mot-objet", implique la consultation du lexique bilingue de ces mots.

3.3.4.4 Le module du transfert de syntaxe

Le module doit effectuer un transfert de syntaxe, proposition à proposition, phrase à phrase, en donnant à chaque syntagme, verbal ou nominal, la place qui lui convient. Ce transfert est pour l'instant très rudimentaire puisqu'il limite au maximum toute modification de l'ordre initial.

3.3.4.5 Le module de création des syntagmes nominaux français

En tenant compte de la hiérarchie qui a pu apparaître lors de l'analyse, le module construira les syntagmes nominaux français. Les adjectifs seront systématiquement placés après les substantifs qu'ils déterminent. Il en est de même pour les compléments des participes, passés et présents, jouant le rôle adjectival.

3.3.4.6 Le module final

Il se borne à rassembler tous ces éléments et à donner comme résultat, une phrase approximativement française mais qui se veut, malgré ses défauts, parfaitement compréhensible.
On remarque que la morphologie n'a jamais été évoquée jusqu'ici. Nous espérons ne pas en avoir besoin. Son absence implique cependant quelques défaillances au niveau de l'interprétation (les genres ne sont pas ou mal reconnus). Pour les combler, il faudrait sans doute avoir recours à un dictionnaire monolingue de grande taille, ce que nous refusons. Nous avons pris le parti de ne pas utiliser la morphologie afin de rester dans les limites de nos objectifs.

3.3.4.7 L'aspect multilingual

Une partie des résultats présentés dans le chapitre IV concernent le néerlandais et le luxembourgeois.
Pour savoir quelle était la qualité multilinguale de notre système, nous avons établi tous les fichiers de données indispensables, en néerlandais et en luxembourgeois (grâce aux conseils et à l'aide de J.-Cl. LEJOSNE). Nous les avons appliqués sans changer une ligne des modules "verbal" et "mots composés". Nous précisons d'ailleurs à ce propos, que nos programmes ne contiennent aucune donnée, qu'une indépendance totale existe entre les programmes et les données. Les résultats concernant le luxembourgeois sont parfaits, ceux concernant le néerlandais le sont presque (il suffirait d'intégrer le traitement de quelques anomalies qui ne perturberait pas l'analyse de l'allemand). Ces essais nous ont convaincu du caractère multilingual profond de notre système.

Dans le chapitre suivant, nous rappellerons quelques caractéristiques du système d'interprétation (4.1) avec ses contextes linguistique et informatique (4.2), puis nous verrons dans le détail la structure de l'automate (4.3) avec la mise en forme du texte (4.3.1), l'analyse lexicale et morphologique (4.3.2), l'analyse syntaxique (4.3.3) et les résultats complets (4.4).

IV.

L'AUTOMATE GERMANIQUE-ROMAN
Structure et fonctionnement

4.1 Caractéristiques générales

Rappelons l'intitulé du titre : *"Un système multilingual d'interprétation automatique, étape du sous-logiciel ANALYSE des langues germaniques"* et ce que sous-tendent les mots qui le composent

4.1.1 Système

Parce qu'il regroupe un ensemble d'idées, logiquement solidaires, en un appareil théorique et parce que cet appareil possède une structure de modules qui fonctionnent tous en interaction, nous l'appellons **"système"** .

Dans sa totalité, il devrait correspondre à un **logiciel** de grande taille, 25000 lignes de programme, écrites en **PL/1 Optimizer.** Ce logiciel est composé de deux **sous-logiciels**, le premier correspondant à l'analyse de la langue source et qui est l'objet de notre thèse, le second, à la génération de la langue cible. Chaque sous-logiciel est divisé en plusieurs **modules**, chaque module étant lui-même constitué de **sous-modules** et de **programmes.**

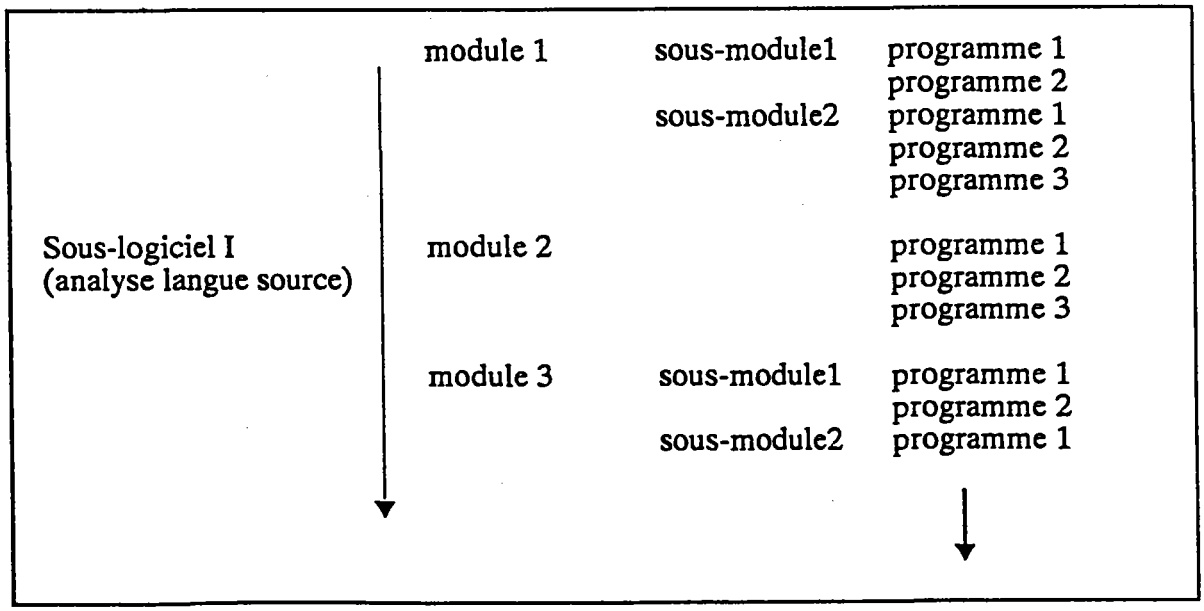

Ces programmes ont rarement plus de 200 lignes, situation qui permet de progresser par petits pas dans l'élaboration de l'automate et de vérifier minutieusement chaque étape.

L'implantation sur micro-ordinateur est un objectif prioritaire qui implique cette modularité. La possibilité d'envisager l'utilisation d'un bi- et même triprocesseur nous amène à déployer des **niveaux** de traitement tels que certains modules pourraient fonctionner simultanément pour un gain de temps calcul appréciable. La dénomination de tous les fichiers utilisés obéit à un ensemble de règles qui permet au système de fonctionner en multilingualité.

• Les données concernant les langues sont rangées dans des fichiers partitionnés (fichiers composés de plusieurs fichiers).

• Les langues traitées sont caractérisées par un suffixe: AL(L) pour l'allemand, OL(L) pour le néerlandais, L(U)X pour le luxembourgeois, A(N)G pour l'anglais, RO(M) pour les formes romanes. Dès lors, le fichier des désinences verbales s'intitulera, pour les différentes langues et dans l'ordre où nous venons de les citer:

.MORPHAL(DESI)
.MORPHOL(DESI)
.MORPHLX(DESI)
.MORPHAG(DESI)
.MORPHRM(DESI)

Le fichier .MORPHAL, quant à lui, regroupera dans ses membres, toutes les données nécessaires à l'analyse de l'allemand, de même que .TEXALL tous les textes étudiés.

• Les programmes et les procédures qui les enchaînent sont indépendants des langues. Leur dénomination est donc générale et nous avons recours comme précédemment à des fichiers partitionnés. Le programme qui découpe un texte en phrases sera :

.CRJF(DECPHR)

A chaque membre de ce fichier de programmes est associée sa forme compilée :

.CHARGE(DECPHR)

Le fichier .PDPROC rassemble des procédures qui gèrent un groupe de programmes ou plus exactement, une succession de modules chargeables (programmes sous forme compilée) et les fichiers de données nécessaires.

.PDPROC(MOTCOMP)

• Le fonctionnement de chaque programme donne lieu à deux sorties distinctes. La première correspond au fichier d'entrée dans lequel sont insérés les résultats, la seconde ne contient que les résultats bruts et disparaîtra en phase opérationnelle.
Les fichiers intermédiaires séquentiels (.TRANSIT1, .TRANSIT2) sont détruits au fur et à mesure, de sorte que la mémoire occupée soit minimale.

• Adapté à tout texte sans la moindre intervention humaine, il fonctionne en temps réel et ne requiert jamais plus de 300 K de mémoire vive. Il pourrait fonctionner actuellement sur un IBM AT (386 ou 486) à la vitesse de l'affichage naturel, beaucoup plus vite, même, en réalité. Il est géré par une procédure écrite dans le langage du système de gestion MVS/TSO, qui peut s'écrire dans d'autres systèmes. Les ordinateurs sur lesquels nous avons travaillé au CIRCE (Centre Inter Régional de Calcul Electronique du CNRS), IBM 370/168 et AMDAHL 470/V7 sont gérés par un système d'exploitation composé de deux logiciels, MVS et JES3.

MVS (Multiple Virtual Storage) gère l'ordinateur et ses composants matériels. T.S.O. (Time Sharing Option) est un sous-système de MVS et offre un mode de traitement autre que le traitement par lots. C'est le type "conversationnel" qui permet d'accéder aux ressources de l'ordinateur sous forme d'un dialogue maintenu entre l'utilisateur et le système.

• Tous les programmes ont été rédigés en **PL1**. Nous en expliquerons le choix en 4.2.2

Niveaux	Modules	Sous-ensembles	Programmes
0	1. Module PREPAR a) mise en forme du texte b) codage c) lexique tassé d) préparation pour le traitement des mots composés		a) lectext, decphr b) prolog c) classmot, tassmot d) mixer1, mixer2, clasmot2 tassmot2, mixer3
	2. Module VERBAL a) traitement du verbe b) Adjectif / Adverbe c) Désambiguïsation Majuscule en tête de phrase		a) filtral, verball, verbal2 b) adv c) desamb
1	3. Module MOTS COMPOSES	MOTCOMP	tirets, fonct1, fonct2, jonct11 jonct12, jonct21, jonct22, gram11, gram12
		MOTCOMPA	fich11, fich12, fich13 aselect, sufall, netall1 netall2, rselect, sufrom, netrom, segmd, segmd1 segmint, recapit, aselect1 sufall1, netall11, reselect1, sufrom1, netrom1
		MOTCOMPB	
2	4. Module SYNTAXE		syntax1, syntax2, syntax3 syntax4, syntax5, syntax6 syntax7, syntax8, syntax9 syntax10, syntax11, syntax12

4.1.2 Multilingualité

Conformément au principe du choix des groupes de langues comme unité de raisonnement (3.2.2.8), et des langues germaniques (3.3.2) dans la cas présent, les programmes sont conçus pour fonctionner dans un environnement multilingual.
Deux exemples illustrent la généralité du logiciel :
- le traitement de la majuscule en début de phrase (voir 4.3.2.3)
- l'utilisation du 'B' et de son contexte dans le repérage des composés (voir 4.3.2.5.2.4)
Dans les deux cas, la fonction, la boucle ou la procédure est ou n'est pas activée selon la langue traitée.

4.1.3 Interprétation

Un système d'interprétation ne traduit pas, dans le sens classique du terme. Il met en correspondance des signifiants de deux langues différentes et ne traduit que des morphèmes. C'est le lecteur qui, précisément, interprète grâce à sa compétence. Il cherche

à extraire de tout texte (non littéraire) suffisamment d'information pour que l'utilisateur qui connaît le domaine dont parle le texte en comprenne le contenu. Cette remarque a deux conséquences essentielles :
- les problèmes d'ambiguïtés, si complexes en ce qui concerne la traduction, sont ici considérablement réduits.
- Il est possible de proposer à l'utilisateur un texte écrit dans sa langue, compréhensible mais d'une mauvaise qualité linguistique (exemples pp. 226-228, pp. 668-674).
Les expériences conduites jusqu'à présent montrent que le spécialiste parvient à reconstruire le texte initial à partir des informations recueillies. Cette reconstruction de la langue-cible est l'objet du second sous-logiciel, et, comme le premier, repose sur un même fondement linguistique : celui du "système dérivationnel" d'une langue ou d'un groupe de langues.
L'**interprétation** sous-entend la compréhension. Le terme interprétation doit être entendu ici comme le synonyme vieilli de traduction. Nous ne pensons pas qu'un système qui doit extraire d'un texte écrit dans une langue naturelle un certain ensemble d'informations à transférer ou non vers une autre langue, puisse fonctionner convenablement à une quelconque étape de son fonctionnement si la **compréhension** n'est pas son principal fondement.
Dans le cas du système présenté, il s'agit de compréhension implicite. Les informations sont extraites d'un texte pour qu'un familier du domaine puisse en déduire le contenu et l'organisation. C'est l'intelligence seule de l'utilisateur qui permet de savoir si le système a, oui ou non, fonctionné correctement, contrairement à ce qui se passe pour la compréhension explicite, où l'on extrait du texte ce qui est nécessaire pour aboutir à des réalisations concrètes (réservation d'une chambre d'hôtel, gestion du trafic routier....). Le terme d'**interprétation** est d'autant plus justifié que les techniques de compréhension utilisées sont trop imprécises actuellement pour mériter le substantif "traduction" :
- absence de dictionnaire au sens usuel du terme.
- absence d'analyse morphologique (sauf pour traitement du verbe)
- génération, dans la phase de transfert, d'unités lexicales inexistantes.
La qualité du style de la sortie ne présente cependant qu'une très faible proportions d'erreurs, elle est indépendante du domaine traité et ne pourra que s'améliorer au fil des versions.

4.1.4 Automatique

Comme une partie de l'analyse, le transfert s'appuie sur la notion de **système dérivationnel**. Pour les langues sur lesquelles nous travaillons, la structure du mot est pratiquement identique : Concaténation à une racine de préverbes, préfixes, infixes, suffixes, morphèmes de déclinaison ou de conjugaison. C'est l'utilisation de la correspondance entre systèmes dérivationnels qui nous permettra de créer automatiquement les mots ou segments de mot compréhensibles.
Exemples d'interprétation des mots composés du texte source :
Les segments romans sont reconnus et retranscrits. Les segments germaniques sont redécoupés, non pas par rapport à la racine, mais par rapport à la base, qui est, en général un préverbe + racine. On réalisera un transfert standard (indépendant du domaine abordé) vers le français, à partir de cette base.
Prenons l'exemple du mot Stromerzeuger découpé de la façon suivante:

1$STROM + 1ER&ZEUG@ER# : à STROM en position initiale correspond COURANT.
Pour l'autre segment, la base est ERZEUG à laquelle correspond PRODUCT. Il ne s'agit pas d'une forme verbale composée, et dans ces conditions, au suffixe ER correspondra le suffixe EUR.

PRODUCTEUR (DE) COURANT

Pour Dauerprüfung nous avons:

1$DAUER + 1PRU*F@UNG# : à DAUER correspond DURÉE et à PRU*F correspond VÉRIFI/VÉRIFIC ce qui avec UNG donne :

VÉRIFICATION (DE) DURÉE.

Le transfert tient compte de la position du segment dans le mot.

Interprétation des mots non composés:

Les mots romans sont réécrits sans correction orthograhique dans la version qui existe. Les mots germaniques, après analyse, sont soit reconstruits en français selon les principes évoqués plus haut, soit traduits en tant que mot-objet, après consultation d'un lexique bilingue de ces mots.
L'interprétation des syntagmes verbaux, le transfert de syntaxe et la création des syntagmes nominaux français tels que la hiérarchie mise à jour par l'analyse soit respectée complètent le second sous-logiciel et donnent du texte une image parfaitement compréhensible malgré ses défauts.

4.1.5 Analyse

Dans l'immense majorité des cas, l'analyse d'un texte n'est pas autre chose que l'analyse morphologique et syntaxique de chaque mot, avec assez rarement une bonne segmentation de chaque phrase. Une telle analyse, quelles que soient sa finesse et sa précision, ne donne pas toujours une idée précise sur le contenu du texte. L'information qu'elle apporte est plus ou moins pertinente selon le degré d'information du décodeur. Si l'on veut privilégier la compréhension, il faut agir en sens contraire, c'est-à-dire ne faire jouer à la morphologie et à la syntaxe au niveau du mot, qu'un rôle secondaire.
En réalité, dans cette optique, ce ne sont plus les mots qui sont les unités de raisonnement, mais l'ensemble des éléments (racines, préverbes, préfixes, infixes, suffixes) qui constituent le système de formation des mots dont le sous-ensemble des racines verbales (racines prédicatives) constitue le noyau.
L'analyse va donc traiter les vecteurs de la compréhension en tenant compte du fait qu'un texte présente une double structure:

- les mots-objets, hors du système-dérivationnel, et des unités plus rares, normalement dérivées mais devenues mots-objets pour des raisons extra-linguistiques (ensemble, fonction...).
- les mots "dérivationnels" (surtout à partir de racines verbales).

• Beaucoup de langues empruntent volontiers, de sorte qu'une des missions de l'analyse consiste à associer chaque mot à son système dérivationnel, qu'il soit celui de la langue ou un système d'emprunt. Ce travail est effectué lors du ***traitement des mots composés*** et de la ***sélection germanique/non germanique.***

• La sélection et la détermination des mots objets ne suffisent pas pour savoir ce dont on parle. Il est indispensable de mettre en évidence les syntagmes nominaux, prépositionnels ou non, c'est ce que réalise ***l'analyseur syntaxique.***

• Tous ces syntagmes s'articulent autour des syntagmes verbaux sans l'étude desquels l'analyseur syntaxique ne pourrait pas fonctionner.
(–> module VERBAL))

4.1.6 Langues germaniques

Le contexte multilingual que nous avons choisi exige que le système fonctionne sur un groupe de langues. Une de leurs caractéristiques, surtout pour l'allemand, est leur polysynthétisme. Cette possibilité de "composer" les mots entre eux, de créer des mots composés de deux, trois, quatre segments et même plus, a posé d'énormes problèmes aux systèmes usuels de Traitement Automatique des Langues Naturelles (TALN). Les composés d'une langue germanique sont en nombre infini et, par conséquent, aucun dictionnaire ne peut les répertorier de façon exhaustive.

Or, la particularité de notre système est de ne pas utiliser des dictionnaires bilingues traditionnels. Ce choix original devait être étayé par des résultats irréfutables. C'est au prix d'un module complexe et de grande taille, présenté dans le chapitre IV, que nous avons traité les mots composés et démontré qu'il était possible de faire fonctionner un système-TALN sans dictionnaire monolingue de grande taille.
Le sous-logiciel ANALYSE a été élaboré, programme par programme, sur l'allemand et testé ensuite, en partie, sur le néerlandais, le luxembourgeois et l'anglais.

4.2 Les contextes

La problématique du Traitement Automatique des Langues Naturelles concerne autant la linguistique que l'informatique.

4.2.1 Le contexte linguistique

4.2.1.1 Les difficultés

Il est nécessaire, semble-t-il, d'adapter les théories linguistiques en fonction des objectifs poursuivis (Traduction Automatique, dialogue homme-machine...), du degré de précision attendu et des contraintes liées à l'automatisation même du traitement. En effet, les théories linguistiques n'ont pas été élaborées dans l'optique d'une application immédiate dans des systèmes de traitement automatique.

Une ressemblance superficielle des langues naturelles avec les langages artificiels (langages de programmation...) ont conduit un grand nombre de chercheurs à appliquer au TALN les méthodes d'analyse utilisées pour traiter les expressions bien formées des langages artificiels. Les particularités des langues naturelles entraînent dans la plupart des cas des modifications et des extensions de modèles. Elles justifient parfois des formalismes propres pour lesquels il est indispensable de construire des fondements théoriques tels qu'on en mesure bien les limites et le pouvoir d'expression.

Les langages artificiels sont créés par l'homme qui les contrôle entièrement. Leur but est de décrire des phénomènes ou des tâches précises à l'aide d'un vocabulaire très restreint et de structures simples. Ils permettent de modéliser et de représenter à un niveau abstrait. Leurs qualités essentielles sont l'absence d'ambiguïtés et de données non-explicites. A chaque mot du langage n'est associé qu'un seul sens. Des facteurs historiques, sociologiques, cognitifs, stylistiques et techniques alimentent les nombreuses différences que nous allons résumer brièvement. Nous voulons ainsi montrer que s'il est possible de traiter de la même manière que pour le langage artificiel certains aspects de l'analyse syntaxique et sémantique du langage naturel, le principe ne peut être généralisé. Dans certains cas, il faudra construire des systèmes d'une grande complexité formelle et technique, quand bien même il ne s'agira que de sous-ensembles bien délimités de la langue. Les difficultés qui apparaissent au fil des différences fixent clairement les bornes actuelles du traitement automatique des langues naturelles.

- Pour un langage naturel, le nombre de phrases correctement construites est infini. On peut multiplier cet infini, bien que cela n'ait aucun sens, en considérant trois des niveaux classiques d'analyse. Sur *le plan lexical*, un dictionnaire n'est jamais exhaustif. Les vocabulaires spécifiques sont en évolution perpétuelle. Sur *le plan syntaxique*, l'ensemble des structures n'est pas déterminé, du fait même de la récursivité. Sur *le plan sémantique*, il se peut que l'ensemble des sens attribués à un mot ne soit pas déterminé. Et l'on ne tient pas compte du fait que le mot ne prend son sens que dans un contexte d'énonciation ! Cette première difficulté explique que le traitement automatique ne puisse s'appliquer aujourd'hui qu'à un sous-ensemble restreint de la langue, sémantiquement bien défini. Tout n'est pas si simple cependant, car il est impossible de figer une langue qui évolue sans cesse (qui crée des mots nouveaux et oublie ceux qui tombent en désuétude). Ces phénomènes sont particulièrement fréquents dans les domaines techniques et scientifiques.

- En langage artificiel, toute erreur de syntaxe entraîne immédiatement une interruption du compilateur, malgré des systèmes complexes de récupération d'erreurs. La langue naturelle autorise quant à elle une plus grande souplesse puisque, dans certains cas, une phrase agrammaticale peut être compréhensible. *"...il existe, en fait, un seuil maximal de distorsion syntaxique, au delà duquel une phrase n'est plus compréhensible. Ce seuil n'est pas fixe et dépend fortement de la signification de la phrase, de sa complexité et de sa forme ainsi que du contexte dans lequel elle a été énoncée".*[1]

- Une troisième source de difficultés sont les ambiguïtés que l'on trouve à des niveaux variés (cf. 1.2) et qui ne sont pas toujours évidentes dans le sens où le lecteur opère souvent naturellement le bon choix. Il est extrêmement difficile de construire une machine qui intègre immédiatement une phrase dans son contexte d'énonciation, contexte dont elle pourrait extraire, comme le fait presqu'inconsciemment l'homme, les données propres à lever des ambiguïtés.

- Rappelons enfin les éléments sous-entendus (ellipses...) ou contractés (anaphores...) qui constituent autant d'éléments implicites et justifie notre approche de la compréhension implicite.

Comme nous le voyons, les problèmes sont nombreux et complexes. Aucun n'est parfaitement résolu, à l'heure actuelle. Aussi, les recherches se sont orientées vers des systèmes appliqués à des sous-ensembles de la langue, afin de limiter le champ des difficultés. A quelques exceptions près, les systèmes de Traduction Automatique ont évolué vers des systèmes d'aide à la traduction.

4.2.1.2 Les solutions de l'ACI

4.2.1.2.1 Les niveaux morphologique et lexical

Il s'agit d'étudier la forme que prennent les mots dans la phrase. La conjugaison des verbes ainsi que les marques de genre et de nombre n'ont pas grande importance dans la stratégie que nous avons définie (cf. 3.2.2 Les principes de l'ACI). Les formes sont reconnues et les catégories identifiées - il faut souligner ici l'avantage de la majuscule en allemand - grâce à des tris rapides et des listes spécifiques ("mots-outils", "mots-objets", "mots-exceptionnels", "foncteurs")[2]. Les "mots-dérivationnels" sont décomposés à partir de listes de racines, préverbes, préfixes, suffixes et morphèmes grammaticaux.

---

(1) A. GAL, G. LAPALME, P. SAINT-DIZIER : *PROLOG pour l'analyse du langage naturel*, Ed. Eyrolles, Paris, 1989, p. 4

(2) cf. 3.2.2.3.2, la classification du lexique

Nous abordons là un des fondements de notre analyse. Partant de la structure du vocabulaire d'une langue, nous avons voulu montrer qu'il était possible de le réduire à une combinatoire. Dès lors, il semble naturel d'exploiter l'hypothèse d'une parenté étymologique pour convertir les mots d'une langue source dans une langue cible.

Dans toute langue, le vocabulaire est illimité pour deux raisons.

- à cause des emprunts aux autres langues (cf. en français : *un ersatz, le hard, le soft, un solo, le couscous...*).
- à cause de la dérivation et de la composition. Des mots simples sont tout à coup affectés d'un ou de plusieurs affixes, *câbler*, *conforter* sont des dérivés récents. En allemand, tous les composés commençant par *Bund-* (*=fédération*) ont été formés après la naissance de la République Fédérale (*Bundesrepublik*) il y a moins de 40 ans (*Bundesbahn, Bundeswehr* etc.).

En plus de ces possibilités d'accroître son vocabulaire, la langue a la possibilité de multiplier les significations d'un même stock de vocables par le procédé de la métaphore (littéralement "déménagement" d'un mot d'une signification à une autre). Par exemple, le mot table est utilisé par plusieurs techniques pour désigner des objets qui n'ont en commun que de présenter une surface plane : *table de logarithmes, table traçante, table à dessin* etc.

Les trois procédés peuvent se conjuguer pour s'appliquer à une même racine : *le coco* (fruit du cocotier) est un mot d'origine portugaise. Ce mot a été utilisé par métaphore pour la tête (*se casser le coco*). La dérivation a donné *cocotier*. Ce mot a fait à son tour l'objet d'une métaphore : *secouer le cocotier*.

Il est donc au total impossible de mettre dans la mémoire d'un ordinateur l'ensemble des mots d'une langue et celui des significations d'un nombre même limité de ces mots.

La réduction du vocabulaire à une combinatoire

Puisque le nombre de suites de lettres entre deux blancs est illimité dans une langue et que le nombre de significations associées à chacune de ces suites de lettres est lui-même indéterminé, il faut procéder à une double réduction :

- celle du nombre illimité de suites de caractères à un nombre fini de suite de caractères
- celle des significations associées à ce nombre fini de suites de caractères à un nombre également fini.

Pour chacun de ces niveaux de réduction, on utilise actuellement les procédés suivants :

- Pour évacuer le plus possible de phénomènes de métaphore, on ne décrit pas le vocabulaire d'une langue "en général", mais le vocabulaire d'un "domaine sémantique clos", par exemple le domaine des mots et locutions décrivant une technique bien délimitée. Dans ce domaine sémantique, les mots sont utilisés avec un de leur sens seulement. En allemand, *Birne* correspond à *poire* pour le jardinier, *convertisseur* pour le sidérurgiste et *ampoule* pour l'électricien. Si l'on décrit la marche d'une aciérie, on associera *Birne* à *convertisseur*.

- On peut considérer que dans une large mesure, les emprunts faits à une langue A sont compris par les gens qui parlent la langue B et la langue C qu'on essaie de mettre en

correspondance par la TAO. De fait, les mots anglais de l'informatique sont compris en France et en Allemagne. Il est donc inutile de chercher à les traduire s'ils figurent dans un texte allemand que l'on interprète en français. L'élimination des mots d'emprunt se fait automatiquement par reconnaissance des formes graphiques (analyse des suites de lettres). Par exemple *hard* ne peut pas être un mot allemand (la seule forme possible serait *hart*), *solo* ne peut être ni un mot allemand ni un mot français etc.

- L'ACI décompose parfaitement les mots simples, dérivés et composés, en racines, affixes et morphèmes grammaticaux. Cette décomposition procède par repérage de constantes (les affixes) par rapport aux variables qui sont les racines supports des dérivations. La pertinence de l'opposition variable/constante tient à ce que les affixes sont beaucoup moins nombreux que les racines auxquelles ils s'associent.

trag-		port-	
denk-	bar	pens-	able
mach-		fais-	

La question qui se pose au terme de cette analyse est de savoir ce que l'on peut faire avec un stock de racines, d'où les emprunts sont éliminés et un stock d'affixes qui, dans l'usage réel de la langue, ne sont jamais utilisés seuls.

Le repérage des racines et des affixes associés dans un mot quelconque fournit la structure étymologique de ce mot :

Préfixe(s)	radical	suffixe(s)
DE	FORM(E)	ER
RE	ECRI-	RE
IN/IM	POSS-	IBLE

En quoi cette analyse facilite-t-elle la conversion des mots d'une langue danhs une autre ?

Les parentés étymologiques dans les langues en contact

Les langues européennes ont une longue histoire commune. Ensemble, elles se sont nourries de mots latins et grecs et au gré des variations de poids relatifs des différents pays, elles ont emprunté beaucoup les unes aux autres. Ces emprunts se sont effectués de deux façons : par emprunt des formes phoniques ou graphiques et par reconstruction.

On peut éliminer ici le cas des emprunts des formes graphiques puisqu'on fait l'hypothèse qu'un mot qui n'a pas une forme graphique "normale" dans la langue source doit se trouver aussi dans la langue cible (cas de *hard*, de *cash*, de *philosophie*...).

Dans le cas d'emprunt par reconstruction d'un mot d'une langue A par une langue B, le processus est le suivant :
L'emprunteur procède à l'analyse étymologique du mot à emprunter. Il établit une correspondance terme à terme entre les racines et affixes reconnus et des racines et affixes de sa langue. Il construit un mot qui, sur la base des correspondances adoptées, est la traduction terme à terme de la structure étymologique reconnue. C'est ainsi que beaucoup de mots qui ont une forme parfaitement allemande sont des traductions des structures étymologiques du latin.

IN -	PRESSIO	BENE -	FACTUM
EIN -	DRUCK	WOHL -	TAT

Notre hypothèse est :

- qu'entre les langues européennes, ces emprunts par reconstruction sont très nombreux.
- que dans l'histoire de chacune des langues, les règles de correspondance des combinatoires sont restées assez stables pour qu'avec un système de correspondances souvent bi-univoques entre les stocks finis de racines et affixes de deux langues A et B, on puisse générer des mots compréhensibles dans la langue A à partir des structures étymologiques. Soit par exemple les mots :

français	SOUS -	ESTIMER
anglais	UNDER-	RATE
allemand	UNTER-	SCHÄTZEN

Il est évident que l'on peut établir une correspondance "en dehors de ces mots" :

SOUS	UNTER	UNDER
ESTIMER	SCHÄTZEN	(TO) RATE

Ces correspondances étant données, on peut traduire mécaniquement l'un des mots dans les deux autres langues.

Dans la réalité des langues, ces reconstructions étymologiques sont plus souvent compréhensibles que correctes, car le seul fait que les éléments de la combinatoire entrent en contact entraîne souvent une modification de la forme de l'un des deux.

Soit les mots

anglais	UNDERWRITE
allemand	UNTERSCHREIBEN

on considèrera comme intuitif qu'ils ont la même structure étymologique dont le correspondant français est

français	SOUS - ECRIRE

Mais dans ce mot, comme dans une série d'autres (inscrire, prescrire) ECRIRE prend la forme SCRIRE (cf. latin SCRIBERE).

La mise en forme réelle des mots imposerait de compliquer considérablement les règles de correspondance entre les éléments des combinatoires et ceci pose le problème du coût de la traduction assistée par ordinateur.

Il semble cependant qu'un système de correspondances simple entre deux stocks finis d'éléments fournisse une assistance appréciable à l'interprétation (SOUS-ECRIRE CHEQUE a un sens) et il est établi que ce niveau d'analyse est celui qui convient pour construire une traduction "intraordinateur" (conversion d'instructions d'une langue dans une autre), où la correction formelle de la traduction n'est qu'une complication.

Partant de la constatation que le vocabulaire de n'importe quelle langue est illimité, nous nous sommes posé le problème de savoir s'il était possible de remonter automa-

tiquement des vocabulaires réels aux stocks finis d'éléments que la combinatoire des différentes langues met en jeu pour le produire.
Les travaux ont établi la possibilité de dissocier les mots composés et les mots dérivés en racines et affixes. En d'autres termes, il nous semble acquis que pour des domaines sémantiques clos (sans métaphores), on peut effectivement ramener le vocabulaire à un ensemble fini d'éléments.

L'hypothèse directrice de la recherche est que les parentés étymologiques des langues européennes permettent de construire un système de correspondance entre les ensembles finis d'éléments des différentes langues et de générer les mots de la langue cible à partir des éléments constitutifs des mots de la langue source.
Cette mise en correspondance d'éléments de deux langues ne génère pas que des formes correctes. Elles sont cependant compréhensibles dans tous les cas.

Lorsque nous avons démarré la construction de l'automate, les techniques informatiques disponibles ou à notre disposition ont lourdement pesé sur le choix que nous commentons plus bas (cf. 4.2.2). Nous avons développé une analyse descendante avec retour en arrière et déterminé l'ordre d'intervention des modules pour réduire les accès fichiers au minimum. Après la mise en forme du texte source et la transformation des phrases en structures basées manipulées par des pointeurs, la première analyse (cf. 4.3.2.1) repère les mots-outils simples (*daß*, ...) les mots-outils disjoints (*so daß, selbst wenn*, ...) ainsi que les expressions numérales.

Avant d'aborder la phase de décomposition lexicale - repérage des mots simples, dérivés, composés et découpage en racine(s) et affixe(s) - il est nécessaire de traiter le verbe pour inclure dans la liste des composés potentiels, les formes verbales composées (*maschineschreiben*, ...). Le module verbal (cf. 4.3.2.2) ne fonctionne que sur les mots du texte placés en début de phrase (la majuscule est alors ambigüe) et sur les mots qui commencent par une minuscule et ne sont pas des mots-outils. La recherche est rapide car elle s'applique à des formes dont 60% sont réellement verbales. Elle s'effectue de la droite vers la gauche pour le test des terminaisons et l'application d'un filtre éliminant les formes qui ne peuvent être verbales, puis de la gauche vers la droite pour la reconnaissance et le découpage de la préverbation, la reconnaissance de la racine, le contrôle du résidu et le codage.

Les deux étapes suivantes peuvent se dérouler en parallèle.

1. - La désambiguïsation de la majuscule en tête de phrase (cf. 4.3.2.3) grâce aux résultats du module verbal et aux fichiers intermédiaires qui contiennent : le texte complet avec les mots-outils, la partie numérale et le verbe codés, la liste de tous les mots commençant par une majuscule et rencontrés à l'intérieur d'une phrase, la liste des mots non codés commençant par une minuscule qui ne sont de ce fait ni mot-outil ni verbe. Lui succède le codage des adjectifs et des adverbes (cf. 4.3.2.4).

2. - La préparation des données pour l'analyse des mots composés et l'analyse proprement dite (cf. 4.3.2.5). On ne retient que les mots de la phrase qui ne sont pas des mots-outils et dont la longueur est supérieure à 6 caractères, formes verbales y compris.

4.2.1.2.2 Le niveau syntaxique

Nous n'avons pas utilisé les formalismes de la logique. Il est apparu que le repérage de certains délimiteurs aboutissait à un bon découpage des syntagmes. Dans un premier temps, il nous a fallu localiser les ponctuations "fortes" (cf. 4.3.3.2.1) pour traiter ensuite les relatives (cf. 4.3.3.2.2-4.3.3.2.3) et les conjonctives (cf. 4.3.3.2.4). L'analyse

se fait de la gauche vers la droite, séquentiellement, avec des retours en arrière (cf. 4.3.3.2.5). le traitement du "ZU" (cf. 4.3.3.2.6) précède l'analyse des syntagmes prépositionnels (cf. 4.3.3.2.7-4.3.3.2.8), des syntagmes nominaux (cf. 4.3.3.2.9-4.3.3.2.10) et des syntagmes verbaux (cf. 4.3.3.2.11).

4.2.2 Le contexte informatique

Lorsque nous avons commencé à travailler sur l'allemand, le centre de recherche Jean Favard utilisait les ressources informatiques du CNRS (Centre Inter Régional de Calcul Electronique à Orsay). Nous avons entré les textes d'essai sur cartes perforées pour les traiter ensuite sur les gros calculateurs de l'époque, la microinformatique n'en étant qu'à ses débuts. Orientés essentiellement vers le calcul numérique, les langages de programmation disponibles présentaient de grosses lacunes en matière de manipulation de chaînes de caractères. Ils ne permettaient pas d'étudier correctement les chaînes riches (majuscules, minuscules et signes diacritiques) et d'une certaine longueur. Le PLI, lié à IBM et disponible au CIRCE sous la forme d'un excellent compilateur, était alors le seul langage de programmation autorisant un traitement confortable des chaînes de caractères (longueur <32760 car.). C'est pourquoi nous l'avons alors retenu pour l'application informatique de nos hypothèses de travail. Le volume important des recherches, le respect des cahiers des charges et la dynamique propre à un petit laboratoire n'ont pas permis la remise en question d'un choix qui, s'il s'imposait en 1980, est maintenant complètement dépassé.
Sa nature procédurale n'a pas toujours permis d'aborder les problèmes comme nous pourrions le faire aujourd'hui. Dans 1.4, nous avons présenté les modèles de la langue et les différents aspects de la théorie transformationnelle qui sert de base au développement de nombreuses grammaires, dont les grammaires logiques (cf. 1.5.8). Le but de ces grammaires était de décrire la structure des phrases et certains phénomènes linguistiques sans qu'il soit question de développer un outil informatique capable de mettre en adéquation la phrase et sa structure. Or, pour un traitement automatique de la langue naturelle, il faut disposer d'algorithmes permettant de déterminer si une phrase correspond à une structure déterminée et, si c'est le cas, la manière dont sont reliés ses différents constituants. Les premiers travaux de ce genre ont concerné l'application des grammaires formelles à la définition des langages artificiels. Nous venons de voir à propos du contexte linguistique (cf. 4.2.1) que pour le langage naturel, il fallait tenir compte de phénomènes beaucoup plus complexes, ce qui complique très sérieusement les structures des grammaires et des analyseurs. Un formalisme s'est petit à petit imposé, celui des grammaires logiques, basées principalement sur le langage PROLOG. Un de ses mérites est la *déclarativité* : un programme PROLOG est en grande partie une suite d'énoncés logiques indiquant des relations entre ceux-ci. Des techniques d'unification visent à mettre en correspondance les éléments d'une phrase avec les composants d'un ensemble de règles décrivant la grammaire. On peut considérer les règles comme des règles de réécriture (génération de phrase). En inversant l'opération, on examine si une suite de mots forme une phrase acceptable (analyse de phrase). Il est ainsi possible de faire correspondre à la phrase analysée une description structurelle. Exécuter un programme, c'est prouver, à partir des énoncés disponibles, qu'un nouvel énoncé est vrai. Le modèle de l'ACI est certes loin des grammaires logiques. On pourrait cependant l'implémenter en PROLOG. L'adéquation du formalisme de la programmation en logique au formalisme de l'ACI serait peut-être moins forte. On conserverait de toutes façons les avantages de la modularité, du mode déclaratif et de la concision.

Avant d'aborder la présentation des différents modules de l'ACI (cf. 4.2.2.4) et afin de mieux cerner ce que peut être un langage déclaratif, nous introduirons rapidement le langage PROLOG en rappelant ses domaines d'application (cf. 4.2.2.1). Nous le placerons dans le cadre linguistique (cf. 4.2.2.2) et proposerons enfin quelques exemples pour illustrer son fonctionnement (cf. 4.2.2.3).

4.2.2.1 Introduction à PROLOG

Utilisée comme mode de représentation et outil de modélisation, la logique apparaît comme un moyen particulièrement adapté au Traitement Automatique des Langues Naturelles. Il s'agit de la logique du premier ordre (logique des clauses de Horn) et pour une représentation sémantique satisfaisante d'énoncés en langue naturelle, des logiques temporelle, modale et non-monotone.
Les champs d'application du langage PROLOG sont variés, qui s'étendent de l'analyse automatique (grammaires logiques...) aux représentations sémantiques en passant par la réalisation d'interfaces intelligentes ou la génération automatique de texte (génération aléatoire, génération à partir d'une représentation interne, explications fournies par un système expert, réponses générées par l'interrogation d'une base de données, traduction automatique ou génération d'un dialogue).
En PROLOG, tout se résume à trois types d'activité :
- On apporte des connaissances au système en *déclarant* des ***faits*** sur des *objets* et leurs interactions.
- On définit des ***règles*** de raisonnement sur ces faits.
- On pose des *questions*.

La structure fondamentale des données est ici l'arbre, véritable fondement des traitements effectués par et en PROLOG.

4.2.2.1.1 L'arbre

L'arbre est composé d'une ***racine*** unique, en haut du schéma. Les ***branches*** partent de la racine en nombre quelconque mais limité et établissent des relations de dominance ou de fraternité entre les ***nœuds*** et les ***feuilles***. Elles se subdivisent au niveau des noeuds. Dans le bas du schéma, on trouve les feuillles.

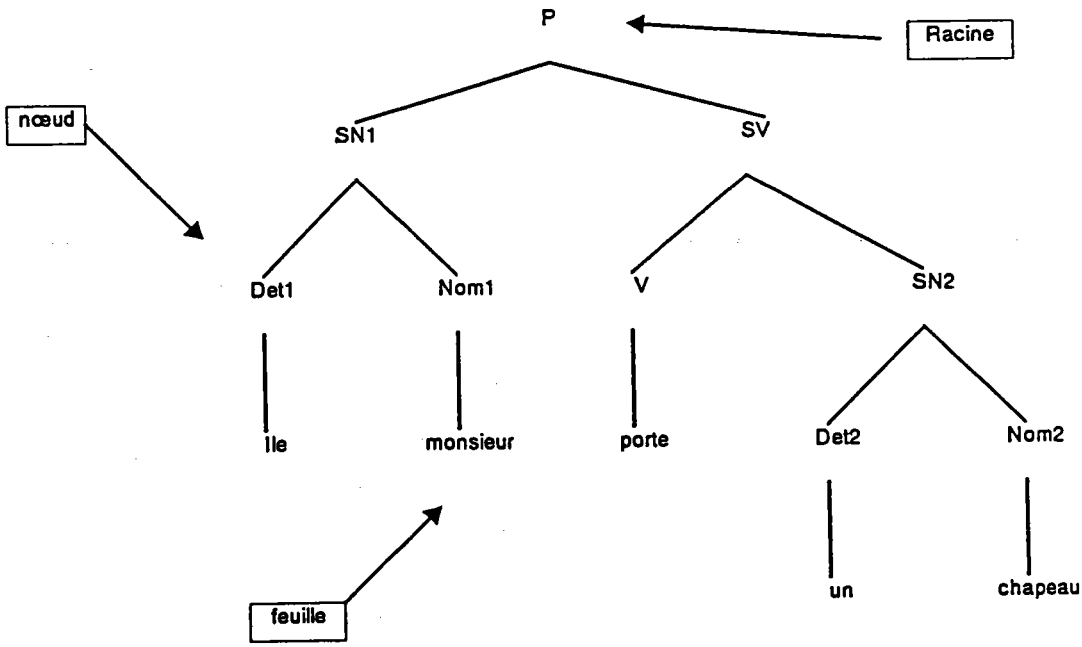

Racine : P
Nœuds : SN1, SV, Det1, Nom1, V, SN2, Det2, Nom2
Feuilles : le, monsieur, porte, un, chapeau

Le nœud SN1 est le père des nœuds Det1 et Nom. Les nœuds Det2 et Nom2 sont les fils du nœud SN2. Det1 et Nom1 sont des frères, ils ont le même père immédiat, SN1.

Pour plus de commodités, les arbres sont représentés de façon applatie :

P(SN1(Det1(le),Nom1(monsieur)),SV(V(porte),SN2(Det2(un),Nom2(chapeau))))

Les éléments frères sont séparés par des virgules, les relations de dominance sont exprimées par les parenthèses.
Lorsqu'on lui pose des questions, PROLOG utilise des fonctions prédéfinies et des mécanismes de démonstration automatique pour effectuer des raisonnements sur les connaissances qu'on lui apporte. Ces connaissances lui sont fournies sous forme de *faits* et de *règles*.

4.2.2.1.2 Les faits

Soit la phrase : *souris est du genre féminin*.

On la décompose en deux objets identifiés par *souris* et *féminin* et une relation *genre*. En logique, *souris* et *féminin* sont deux constantes qui permettent de définir le prédicat :

```
genre(argument1,argument2).
```

On dira par convention que argument1 représente le mot dont on définit le genre, et argument2, le genre.

En PROLOG, on obtient **le fait** :

```
genre(souris,feminin).
```

Dans le contexte du langage de programmation, on parle de **fait** au niveau sémantique et de **terme** au niveau syntaxique. On peut définir un fait avec un nombre quelconque d'arguments. Une relation comme genre aura toujours le même nombre d'arguments et chaque argument aura toujours la même signification. Le fait énonce une propriété ou une relation générale. Les arguments sont des valeurs concrètes qui identifient les entités qui satisfont la propriété ou la relation. On peut définir un fait sans argument(s) :

```
syntagme_nominal.
```

Le fait a alors un caractère absolu. Si le fait a un seul argument, il énonce en général une propriété sur un ensemble d'objets qu'il admet comme argument.

```
determinant(le).
determinant(la).
nom(souris).
nom(chat).
```

le et *la* ont la propriété d'être un déterminant. *Souris* et *chat* ont la propriété d'être un nom.

Les faits qui appartiennent à un programme sont vrais. Leur ensemble constitue une base de faits. Cette base de faits peut être créée à l'aide d'un éditeur puis interprétée par PROLOG ou introduite en mode interactif. Dans la cas d'applications répétées, on range la base de faits dans un fichier. On peut interroger la base de faits.

4.2.2.1.3 Les questions

La question reprend alors la forme du fait précédée d'un symbole spécial. Elle peut être élémentaire ou utiliser des variables. Pour répondre à une question posée, PROLOG parcourt la base de faits pour y rechercher les faits qui correspondent au fait de la question. Deux faits correspondent si leurs prédicats sont identiques et si leurs arguments de même rang sont les mêmes. Si PROLOG trouve un fait qui correspond à la question, il répond yes. Sinon, il répond no.

Lorsqu'on fait appel à des variables, PROLOG parcourt la base de faits avec les variables libres au départ et recherche un fait qui corresponde à la question. Si un argument est représenté par une variable libre, PROLOG va permettre à cet argument de correspondre à n'importe quel argument de même rang dans le fait, quel qu'il soit.

```
deteste(pierre,chien).
deteste(pierre,oiseau).
deteste(paul,oiseau).

? - deteste(pierre,X).
```

A la question *Y a-t-il quelque chose que Pierre déteste*, PROLOG répond :

```
X=chien
```

Au départ, X est libre. PROLOG va trouver un fait dont le prédicat est deteste et le premier argument pierre. X représentera alors le deuxième argument du fait, quel qu'il soit. Le premier fait trouvé (la recherche s'effectue de haut en bas) est :

```
deteste(pierre,chien).
```

X représente chien. X est ***instancié*** à chien. PROLOG marque l'endroit de la base où la correspondance est trouvée pour repartir éventuellement du marqueur, si la recherche se poursuit. On dit que PROLOG essaye de ***re-satisfaire*** la question.

Le prochain fait est : `deteste(pierre,oiseau).`

X est alors instancié à oiseau.

Il est possible de compliquer la question et de demander *Pierre et Paul se détestent-ils ?* PROLOG devra satisfaire deux buts pour résoudre le problème, en demandant si *Pierre déteste Paul* et si *Paul déteste Pierre.*

Soit la base :

```
deteste(pierre,chien).
deteste(pierre,oiseau).
deteste(paul,oiseau).
deteste(paul,pierre).
```

Pour exprimer la conjonction de deux buts, nous écrirons :

```
? - deteste(pierre,paul), deteste(paul,pierre).
```

PROLOG va chercher à satisfaire un but après l'autre en cherchant pour chacun un but qui lui corresponde dans la base de faits. Le deuxième but est vérifié, pas le premier. La réponse à la totalité de la question sera no.

On peut combiner les conjonctions et l'utilisation de variables. Pour savoir s'il y a quelque chose que Pierre et Paul détestent tous les deux. Il faudra vérifier les buts :

- trouver un objet X que Pierre déteste
- voir si Paul déteste cet X, quel qu'il soit

```
? - deteste(pierre,X), deteste(paul,X).
```

PROLOG essaie de satisfaire le premier but. Si le fait existe dans la base, il marque l'endroit et essaie de satisfaire le deuxième but.

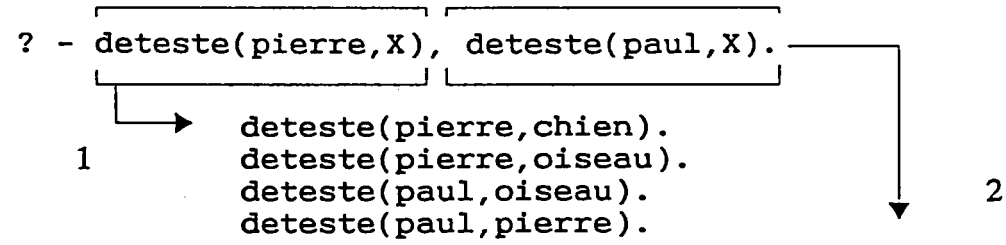

1. le premier but est vérifié. X est instancié à chien.
2. Echec du deuxième but. On effectue un retour en arrière[1].

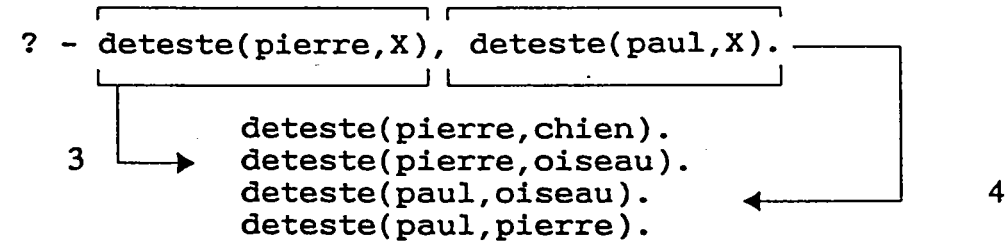

3. La valeur de x est effacée. On essaie de re-satisfaire le premier but qui est à nouveau réussi. On instancie X à oiseau.
4. Le deuxième but est également réussi.

4.2.2.1.4 Les règles

Il s'agit d'un moyen d'expression très puissant qui permet de généraliser la façon d'exprimer des connaissances et confère à PROLOG un pouvoir déductif.
Soit la relation : pere_de(X,Y). qui énonce de façon générale que X est père de Y.
Soit la base de faits :

```
pere_de(jean,paul).
pere_de(robert,henri).
pere_de(pierre,marcel).
pere_de(dominique,pierre).
```

---

(1) La notion de retour en arrière est très importante en PROLOG. Nous donnons plus de détails p. 266

A partir de ces faits, on veut introduire la relation : `grand_pere(X,Y).` qui énonce que X est le grand-père de Y.

On pourrait céer une liste de nouveaux faits. On préfère définir une **règle** selon laquelle, si nous avons X, Y et Z tels qu'il existe :

```
pere_de(X,Y).
pere_de(Y,Z).
```

on peut déduire que X est le grand-père de Z.

Nous avons deux faits à vérifier en même temps, avec une variable commune : Y. La règle en PROLOG comporte deux parties : le résultat à déduire et les conditions. Elle s'écrira ici :

```
grand_pere(X,Z) :- pere_de(Y,Z),pere_de(X,Y).
```

La règle, en PROLOG, permet d'énoncer une loi générale, qu'il y ait ou non, à un instant donné, des solutions à ces règles. Nous reprenons l'exemple ci-dessus et posons la question :

```
? - grand_pere(X,marcel).
```

On ne peut pas effectuer de recherche directement dans la base de faits puisqu'il n'existe pas de fait `grand_pere`.

PROLOG fonctionne de la façon suivante : il unifie tout d'abord la question avec la tête de la règle `grand_pere( , )`. L'unification réussit et Z est lié à `marcel`. Toute occurrence de Z dans la règle est liée à `marcel`. La règle devient :

```
grand_pere(X,marcel) :- pere_de(Y,marcel),pere_de(X,Y).
```

PROLOG va chercher à démontrer la partie droite de la règle, pas à pas. Il doit trouver un fait ou une autre règle qui s'apparie avec `pere_de(Y,marcel)`. Il trouve `Y=pierre`. Les occurences de Y sont réécrites en `pierre`. Il traite la deuxième partie de la règle `pere_de(X,pierre)`. et trouve `x=dominique`. La valeur de X est repercutée au niveau de la règle où la variable X était restée libre. La réponse livrée, le système peut poursuivre la recherche d'autres solutions.

Une particularité très intéressante de PROLOG est de pouvoir définir plusieurs clauses avec la même tête. On parle alors d'un paquet de clauses.

Voyons maintenant ce que signifie *unification*, une opération de base en PROLOG.

4.2.2.1.5 Le mécanisme d'unification

L'unification permet de tester, à l'aide de substitutions si deux arbres ou deux sous-arbres sont identiques. L'unification permet aussi d'accéder aux différents sous-constituants d'un terme par l'emploi de variables qui vont s'unifier avec une partie d'un

terme. Dans un terme, substituer une variable par un terme, c'est remplacer toutes les occurences de cette variable par ce terme.

`S(X,T).` signifie qu'on va remplacer toutes les occurences de `X` par le terme `T`, dans un autre terme.

`S(X,a(b,c,D))` appliquée à `V=b(X,h(Y,X))` donnera :

`S(V)=b(a(b,c,D),h(Y,a(b,c,D))).`

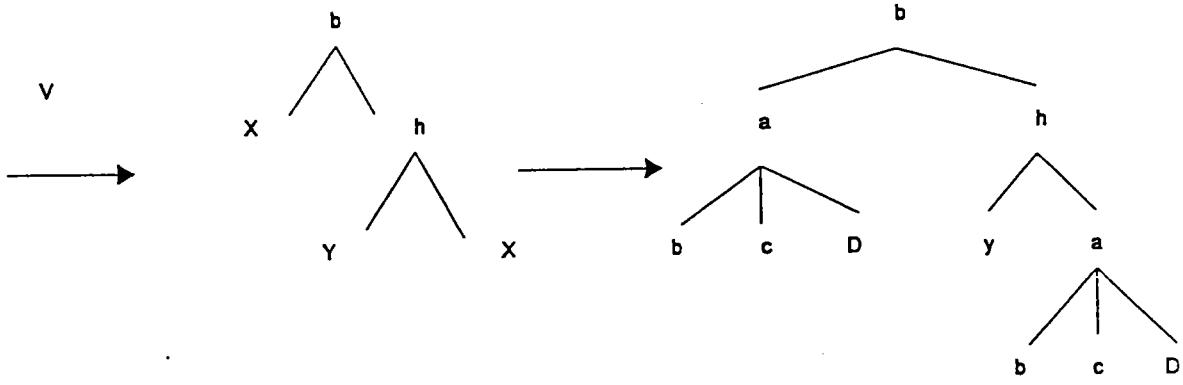

Comme certains autres langages de programmation, PROLOG autorise la récursivité.

4.2.2.1.6 La récursivité

Inspirée des schémas de raisonnement par récurrence, elle constitue un processus fini et limité et repose sur :

- La condition initiale qui est donnée par l'appel récursif au paquet de clauses.
- Le schéma de développement
- La condition d'arrêt qui est exprimée par une autre clause du paquet. Elle doit être examinée avant chaque nouvel appel de la récursivité, ce qui implique qu'elle soit la première clause du paquet.

On peut donner un exemple de récursivité avec la recherche d'un ou plusieurs chemins entre deux nœuds d'un graphe.

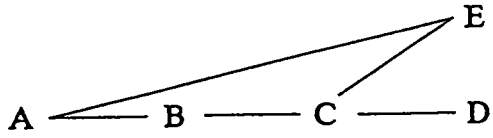

Un arc exprime une relation entre deux sommets. On peut représenter un graphe en PROLOG par des faits qui auraient la forme `arc(X,Y).` pour signifier qu'un arc va de `X` à `Y`.

```
arc(a,b).
arc(b,c).
arc(c,e).
arc(c,d).
arc(a,e).
```

Existe-t-il un chemin du nœud a au nœud d ?

```
? - chemin(a,d).
```

Le prédicat `chemin(X,Y).` sera vrai s'il existe un chemin entre X et Y. Le problème se décompose en deux cas, c'est à dire deux clauses pour le paquet `chemin`.

Clause 1 : le chemin est élémentaire, il existe un chemin entre deux points si un arc les relie.
Clause 2 : le chemin n'est pas élémentaire. Il y a un chemin de X à Y s'il existe Z, avec un chemin de X à Z et un chemin de Z à Y.

En décomposant le problème en deux parties, nous définissons un schéma récursif. Pour le cas élémentaire, il existe un arc reliant X à Y. Pour le cas général, le problème est résolu au rang inférieur (il y a un chemin de Z à Y).

Les clauses du paquet chemin sont numérotées :

```
1. chemin(X,Y) :- arc(X,Y).

2. chemin(X,Y) :-
       arc(Z,Y),
       chemin(Z,Y).
```

L'appel se fait par `? - chemin(a,d).`

Première étape :

Clause 1 :	`chemin(X,Y) :- arc(X,Y).`
Unification :	`chemin(a,d) :- arc(a,d).` ---> échec
Clause 2 :	`chemin(X,Y) :- arc(X,Z), chemin(Z,Y).`
Unification :	`chemin(a,d) :- arc(a,Z), chemin(Z,d).`

La fait `arc(a,b).` permet d'unifier Z=b.
Il faut démontrer `chemin(b,d).` pour que `chemin(a,d).` soit vérifié.

Deuxième étape :

Clause 1 :	`chemin(X,Y) :- arc(X,Y).`
Unification :	`chemin(b,d) :- arc(b,d).` ---> échec
Clause 2 :	`chemin(X,Y) :- arc(X,Z), chemin(Z,Y).`
Unification :	`chemin(b,d) :- arc(b,Z), chemin(Z,d).`

Le fait `arc(b,c).` permet d'unifier Z=c. L'appel récursif est `chemin(c,d).`

Troisième étape :

Clause 1 :	`chemin(X,Y) :- arc(X,Y).`
Unification :	`chemin(c,d) :- arc(c,d).` ---> succès

L'appel à l'étape 3 est démontré. L'appel récursif à l'étape 2 l'est aussi. Il n'y a plus d'autres conditions à démontrer. Il en va de même pour l'étape 1.

L'appel ?- chemin(a,d). est donc démontré, après l'épuisement de la suite d'appels récursifs. Lorsqu'il y a d'autres solutions, PROLOG les recherche toutes. Si l'on ajoute un fait, par exemple : arc(b,d)., on peut aller de a à d selon deux chemins

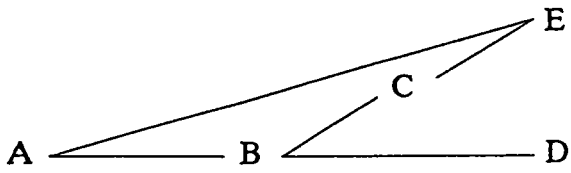

(a-b-c-d et a-b-d).

On peut introduire des variantes dans la façon d'utiliser chemin, selon que les arguments sont libres ou instanciés.

Argument 1 libre : ?- chemin(X,d). PROLOG nous donnera comme résultat les sommets X du graphe à partir desquels il existe un chemin jusqu'à d.

Argument 2 libre : ?- chemin(a,X). PROLOG nous donnera tous les sommets X accessibles à partir de a.

Si les deux arguments sont libres, PROLOG donnera tous les chemins du graphe.

En ajoutant un troisième argument L à la clause chemin pour désigner la longueur du chemin de X à Y (nombre d'arcs pour aller de X à Y), le calcul pourra s'effectuer en considérant que pour un chemin élémentaire nous aurons :

```
chemin(X,Y,1) :- arc(X,Y).
```

et pour un chemin non élémentaire, en posant L1 pour l'arc Z-Y :

```
chemin(X,Y,L) :- arc(X,Z),
      chemin(Z,Y,L1),
      L is L1+1.
```

PROLOG gère la récursivité par un mécanisme de pile relativement classique.

4.2.2.1.7 Mécanismes de contrôle

Lorsqu'il exécute une tâche, PROLOG gère tous les mécanismes :

- appels des règles
- unification
- retour arrière

Lorsque l'exécution est stoppée à un instant donné, on dispose de :

- points qui ont été démontrés
- points en cours de démonstration
- points qui restent à démontrer

Dans les deux premiers cas, une partie des règles n'a pas été utilisée. Elles constituent la liste des choix restants. L'état de l'exécution en cours peut évoluer selon deux processus :

- progression classique dans les points à démontrer. Les appels sont exécutés séquentiellement dans l'ordre des clauses du paquet.

- retour en arrière qui intervient après un succès pour rechercher d'autres solutions à un problème ou après un échec sur un point à démontrer.

PROLOG propose deux *prédicats prédéfinis* qui permettent de contrôler la résolution, le prédicat qui provoque l'échec d'une clause et le prédicat qui supprime des choix. Ce dernier permet d'éviter d'effectuer toutes les recherches lorsque l'on veut savoir s'il existe au moins une solution à un problème. Il facilite également l'écriture d'expressions telles que si... alors... sinon...

4.2.2.1.8 Les prédicats définis

Ces prédicats sont définis par PROLOG et non par les règles qu'introduit le programmeur. Ils offrent des possibilités que l'on ne pourrait pas obtenir en PROLOG pur et mettent à disposition des outils pratiques (prédicats d'entrée-sortie, introduction de nouvelles clauses, classification des termes, traitement des clauses comme des termes, modification du retour arrière, manipulation des fichiers, observation du déroulement d'un programme...).

4.2.2.1.9 Le retour en arrière et la coupure

La coupure permet de signaler à PROLOG les choix antérieurs qu'il n'est pas nécessaire de reconsidérer en cas de retour arrière dans l'ensemble des buts déjà satisfaits. Le programme s'exécute plus vite car il ne perd pas de temps à essayer de satisfaire des buts dont on sait par avance qu'ils n'apportent pas de solution. On économise de la mémoire car il devient inutile de stocker des points de retour arrière pour une recherche ultérieure.

Avant de décrire ce qui sert de cadre linguistique pour l'application de PROLOG au traitement du langage naturel, nous devons dire encore quelques mots sur *les listes*.

4.2.2.1.10 Les listes

En PROLOG, on utilise très fréquemment une structure de données particulière : la liste. Elle réunit un ensemble ordonné d'objets (et peut être vide).

Soit la liste [les,grands,hommes]. Les crochets ouvrant et fermant indiquent le début et la fin de la liste. Les éléments sont séparés par une virgule. Une liste est soit une liste vide (sans éléments), soit une structure à deux composants : la tête et la queue. On représente la fin de la liste, selon l'usage, comme une queue qui est la liste vide et s'écrit []. La tête et la queue sont les composants du symbole fonctionnel point qui s'écrit ".".On peut la représenter sous la forme d'un arbre :

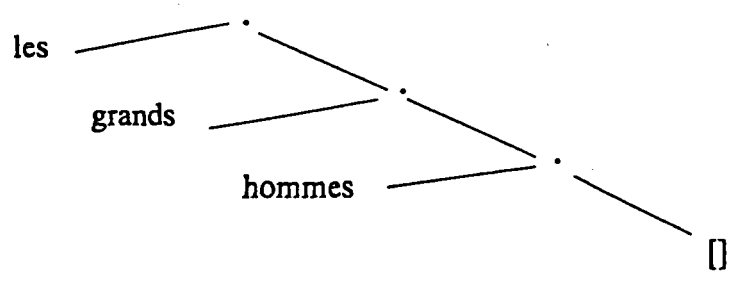

La liste représente un ensemble d'objets, sans relations. Au niveau de l'unification, l'opération essentielle est la séparation de la tête et de la queue. Il existe un certain nombre d'opérations de base sur les listes (recherche d'un élément dans une liste, opérations ensemblistes, concaténation).

4.2.2.2 PROLOG et le cadre linguistique

Nous mettrons surtout l'accent sur l'aspect syntaxique de l'analyse, en partant de la théorie transformationnelle. Les grammaires logiques que nous verrons dans le paragraphe 4.2.2.3 s'en sont inspirées. Dans un premier temps, nous rappelons ce que sont les *grammaires formelles* (4.2.2.2.1), nous présentons les notions de *catégories syntaxiques* (4.2.2.2.2) et d'*arbres syntaxiques* (4.2.2.2.3). Ensuite, nous introduirons brièvement la notion de *structure du lexique* (4.2.2.2.4) pour terminer sur *les transformations* (4.2.2.2.5). En conclusion (4.2.2.2.6), nous citons des grammaires récentes et ce qu'elles apportent de nouveau.

Une phrase en langage naturel est composée de structures appelées *syntagmes*, construits autour du nom ou du verbe. Ils sont composés de *mots* que l'on considère ici comme l'élément de base. Les mots et leurs caractéristiques sont rangés dans un *lexique* qui devient essentiel, au fil des recherches en Traitement Automatique des Langues Naturelles. Les grammaires sont plutôt considérées comme des outils destinés à contrôler la cohérence des phrases et à construire une compréhension de l'énoncé. On utilise des systèmes abstraits de règles pour représenter ces syntagmes qui reflètent la structure de la phrase. Les règles de type 2 sont augmentées par l'emploi d'arguments qui leur confère une certaine dépendance vis à vis du contexte (règles de type 1).

4.2.2.2.1 Les grammaires formelles

Regroupées en trois classes, les grammaires formelles permettent de décrire les structures qui explicitent les liens et les relations entre les mots qui composent une phrase. Nous avons vu qu'une grammaires de type 2 que l'on appelle également grammaire hors contexte (cf. 1.4.3.1.2) est un quadruplet (V,T,P,S) :

- V est l'ensemble des symboles non-terminaux qui représentent les catégories syntaxques.
- T est l'ensemble fini d'éléments terminaux qui sont ici les mots de la langue.
- P est un ensemble de règles. Chaque règle a la forme α --> β , α étant un élément de V et β une suite ordonnée d'éléments de $V \cup T$.
- S est le symbole initial ou axiome. Dans notre cas, c'est le symbole Phrase (P).

La grammaire permet d'engendrer une phrase (génération de texte). On dit que ses règles sont des règles de réécriture (α se réécrit en la séquence de symboles β, chaque symbole se réécrivant en d'autres symboles jusqu'à ce qu'ils soient tous des symboles terminaux). Dans une opération inverse, la grammaire permet de reconnaître si une suite de mots forme une phrase acceptable (analyse de phrase).

L'analyse d'une phrase produit une description structurelle qu'il est possible de schématiser par un arbre. La règle suivante signifie qu'une structure A est composée de trois sous-structures B, C et D :

A ---> B, C, D

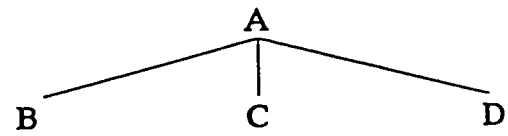

Un arbre représentera la même chose :
Soit une suite de règles dans lesquelles nous allons représenter les symboles terminaux en minuscules et entre crochets, et les symboles non-terminaux en majuscules.

1. A ---> B, C, D

2. B ---> [b]
3. B ---> [b], B

4. C ---> [c]

5. D ---> [d]
6. D ---> [d], D

Ces règles permettent de reconnaître les phrases suivantes :

1. b, b, c, d, d.
2. b, c, d, d, d.

b, c, c, d ne peut être reconnue puisqu'il n'est possible de reconnaître qu'un seul c.

Nous pouvons représenter la structure de la phrase 1 par l'arbre syntaxique suivant :

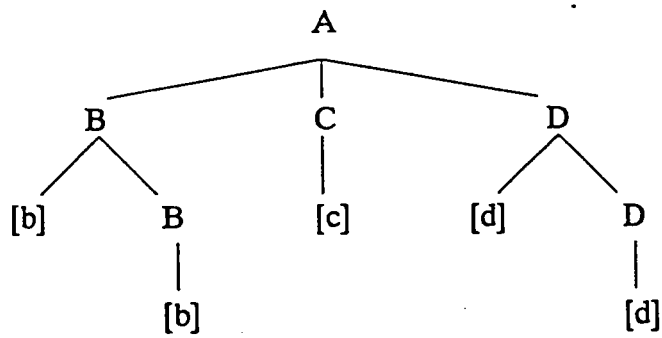

A est la racine. B, B, C, D et D sont les nœuds. [b], [b], [c], [d] et [d] sont les feuilles.

Les règles B ---> [b], B et D --->[d], D font appel à elles-mêmes, elles sont récursives.

Afin de préciser la forme et la nature des règles qui sont utilisées pour le traitement de la langue naturelle, nous allons passer en revue les notions qui vont nous permettre de décrire la structure d'une phrase et d'en modéliser la description.

4.2.2.2.2 Les catégories syntaxiques

Les catégories lexicales de base sont :

- le nom (N) : *chat, souris, Paul...*
- le déterminant (DET) : *le, la, un...*
- l'adjectif (A) : *gros, petit, vert...*
- l'adverbe (ADV) : *hier, très...*
- le verbe (V) : *mange, porte...*
- l'auxiliaire (AUX) : *été, auront...*
- la préposition (PREP) : *à, sur, pour...*
- le pronom (PRO) : *qui, lesquels*

- la conjonction (CONJ) : *mais, ou, car...*

Dans la théorie standard, on définit les catégories à partir des catégories de base évoquées plus haut :

- la phrase (P) : le chat mange la souris...
- Le syntagme nominal (SN): la plus grande ville, l'homme que je vois...
- le syntagme verbal (SV) : portera, mange la petite souris...
- le syntagme prépositionnel (SP) : sur la table, sous le parapluie...
- le syntagme adjectival (SA) : le plus amusant, très faible...
- le syntagme adverbial (SADV) : de moins en moins souvent...

On va décrire les constituants de la phrase à l'aide de règles (syntagmatiques). Pour dire qu'une phrase P est composée d'un syntagme nominal (SN) et d'un syntagme verbal (SV), on écrit la règle :

P --> SN, SV

On peut trouver de nombreuses possibilités :

SN --> DET, N
SN --> DET, N, SP
SN --> N, SA

SV --> AUX,V
SV --> AUX, V, SN
SV --> V, N
SV --> V, SP

SP --> PREP, SN

La tendance est à la recherche de règles générales pour aboutir plus facilement à une description exhaustive de la langue.
Ce sont les *règles d'insertion lexicale* qui permettent l'insertion de mots appartenant au vocabulaire terminal sous les catégories lexicales comme N, DET, V, A, ADV...

4.2.2.2.3 Les arbres syntaxiques

On dit que la construction d'une phrase est correcte si un ensemble de règles permet de décrire complètement sa structure, que l'on représente souvent sous la forme d'un arbre syntaxique :

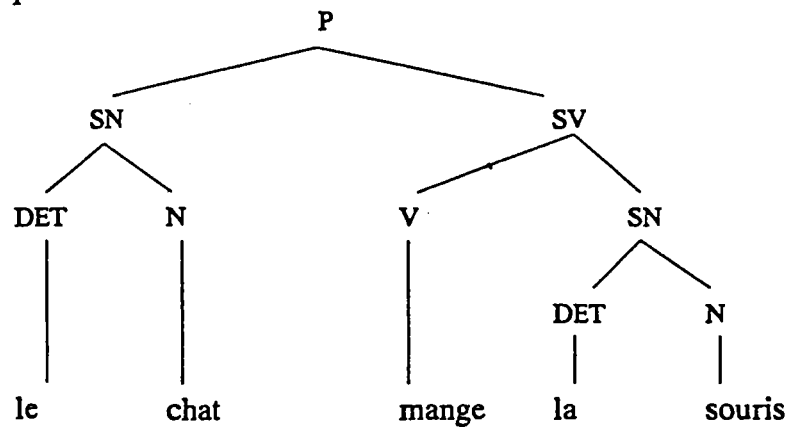

Nous avons vu dans le chapitre I qu'une phrase peut avoir plusieurs arbres syntaxiques lorsque sa construction présente des ambiguïtés.

4.2.2.2.4 Les structures du lexique

Le vocabulaire est composé de mots auxquels sont associées des caractéristiques phonologiques, morphologiques, syntaxiques et sémantiques. En ce qui concerne la morphologie et selon les langues, le mot peut prendre différentes formes liées au genre, au nombre, à la personne, au temps, au mode, à la voix... Les rapports entre mots pourront imposer une forme, ce qui conduit à la notion d'accord. Les lexiques contiennent habituellement un ensemble de *règles morphologiques* qui déterminent les formes que prendront les mots. Des *règles de formation* permettront de dériver des mots simples. Il faut y ajouter un traitement important des exceptions.

Nous avons vu que chaque mot appartient à une catégorie syntaxique. Les indications qui en découlent sont insuffisantes pour mener une analyse classique. Aussi doit-on leur adjoindre des sous-catégories en rapport avec l'environnement qu'ils acceptent. On est alors amené à considérer un ensemble de modifications, indispensables pour préciser le sens du mot. Ainsi pour le verbe *monter*, aurons-nous la forme transitive (*monter la garde, monter la tente...*), la forme intransitive (*monter à cheval, monter à l'assaut, la route monte, les blés montent...*) et la forme pronominale (*les frais se montent à cent francs, il se monte en linge...*). Il est impossible de décrire tous les contextes pour chaque entrée du dictionnaire. On cherche par conséquent à regrouper en classes sémantiques représentées par des traits sémantiques "tout ce qui peut modifier". Ces traits varient selon les auteurs car ce domaine de recherche est en pleine évolution. Ils traduisent des relations ou des rôles thématiques tels que *agent, instrument, but, moyen...* Il est de plus fréquent que l'on ajoute à ces rôles des sous-types sémantiques primitifs pour préciser la nature du complément : *humain, objet, abstrait...* Nous verrons dans le paragraphe 4.2.3.3 comment PROLOG les met en œuvre.

Lorsque l'environnement donné d'un mot présente plusieurs variantes, on peut par exemple assurer la permutation de deux compléments et faire l'économie d'une duplication des données de sous-catégorisation grâce à l'emploi de *règles de redondance*. Des *règles de restructuration* redéfinissent l'environnement à la suite d'une transformation (voix active --> voix passive...).

4.2.2.2.5 Les transformations

Les règles de description des structures syntagmatiques donnent la structure de phrases simples et correctes. En simplifiant, des phrases simples peuvent être combinées ou des structures de ces phrases peuvent être déplacées selon des règles précises pour former des phrases plus complexes. Ces mécanismes de construction s'appellent les transformations. Elles complètent le composant génératif dans la théorie transformationnelle standard. Parmi les transformations importantes, le *Qu-mouvement* qui permet de passer de la forme affirmative à la forme interrogative et le *SN-mouvement* qui assure le déplacement du syntagme nominal comme dans le passage de la forme active à la forme passive.

4.2.2.2.6 Conclusion

De nombreux modèles informatiques s'efforcent de manipuler des règles de transformation (composant transformationnel) et des règles qui décrivent les structures de base (composant génératif). Ils apparaissent souvent comme des variantes de notation de la théorie standard, mieux adaptés aux modes d'expression utilisés en informatique et orientés vers une certaine simplification.

Dans les grammaires à structure syntagmatique généralisée (cf. 1.4.2.4.3) avec l'emploi de catégories dérivées et dans les grammaires lexicales fonctionnelles (cf. 1.4.3.6.2) avec l'emploi de méta-variables, une notation supplémentaire permet d'incorporer le composant transformationnel dans le composant de base. Parmi les grammaires qui accordent encore plus d'importance au lexique, on peut citer les grammaires syntagmatiques dirigées par la tête (HPSG)[1], les grammaires d'adjonction d'arbre (TAG)[2] et les grammaires d'unification (cf. 1.4.3.6.1).

Les grammaires logiques (cf. 1.5.8) que nous avons plutôt considérées comme des outils que comme des modèles parce qu'elles sont issues des techniques de programmation en logique, font appel à des formalismes qui s'appliquent à des descriptions linguistiques très proches de la théorie transformationnelle : les grammaires de métamorphose (cf. 1.5.8.1), les grammaires à clauses définies d'implantation plus simple, les grammaires d'extraposition[3] traitant le mouvement des constituants vers la gauche et les grammaires modifiant la structure[4].

4.2.2.3 PROLOG et l'analyse automatique

Comme nous l'avons dit dans l'introduction du paragraphe 4.2.2, PROLOG est une succession d'énoncés logiques traduisant des relations entre eux. Exécuter un programme revient à prouver la véracité d'un nouvel énoncé à partir de ceux dont on dispose.

Prenons l'exemple classique de la structure (*p*) qui représente une phrase composée d'un syntagme nominal (*sn*) et d'un syntagme verbal (*sv*). Le syntagme nominal (*sn*) pourrait être composé d'un déterminant (*det*) et d'un nom (*n*), le syntagme verbal d'un verbe (*v*) ou d'un verbe (*v*) et d'un syntagme nominal (*sn*). Ceci donnerait la grammaire en forme logique :

$$p = sn \wedge sv$$
$$sn = det \wedge n$$
$$sv = v \vee (v \wedge sn)$$

Nous cherchons à savoir si la phrase *le chat mange la souris* est correcte. Il faut donc montrer que *p* est vrai. Pour cela, il faut identifier un *sn* et un *sv*. Un *sn* est composé d'un déterminant *det* et d'un nom *n* : cela correspond bien à *le chat*. Le reste de la phrase doit correspondre à un *sv* composé d'un verbe *v* (*mange*) et d'un syntagme nominal *sn* (*la souris*). On prouve ainsi que la structure de la phrase correspond bien à la grammaire définie plus haut.

La phrase est considérée comme une suite de mots que PROLOG range dans une liste :

```
[le, chat, mange, la, souris].
```

Codons maintenant les règles de grammaire :

---

(1) C. POLLARD : *Generalized Phrase structure grammars, head grammars and natural languages*, Cambridge university press, New York, 1987

(2) A. JOSHI : "Tree adjoining grammars and their relevance to generation" in *Natural language generation*, Kempen, Nijhoff Publishers, Dordrecht (Actes NATO advances research workshop on "Natural language generation"), Nimègue, 1986, pp. 233-252

(3) F. PEREIRA : "Extraposition grammars", *Computational linguistics*, vol. 7, 1981

(4) V. DAHL, McCORD : "Treating coordination in logic grammars", *American journal of computational linguistics*, 7,1, 1983, pp. 32-40

- *Un symbole non-terminal* sera représenté par un prédicat à deux arguments (le premier indique la chaîne d'entrée, le second indique ce qu'il reste de la chaîne après son traitement par le prédicat). Ce type de représentation s'appelle *une liste de différence*. Sa conception remonte aux premiers travaux effectués sur les grammaires de métamorphose par COLMERAUER[1].

Nous définissons alors le syntagme verbal de la façon suivante :

```
sv(LO,L) :- v(LO,L).
sv(LO,L) :- v(LO,L1), sn(L1,L).
```

Les paramètres utilisés en argument permettent de connecter les différentes listes. Pour la première règle, le syntagme n'est composé que d'un verbe, les listes du syntagme sont donc les mêmes que celles du verbe. Pour la deuxième règle, la liste d'entrée du verbe est la liste d'entrée du syntagme, mais sa liste de sortie est transmise en liste d'entrée au syntagme nominal pour analyse. Sa liste de sortie sera la liste de sortie du syntagme.

- Pour vérifier la présence d'*un symbole terminal*, on écrit une règle qui contrôle la présence du terminal au début de la chaîne et donne la suite de la chaîne en sortie. En représentant une liste composée d'une tête (le mot en début de chaîne) et d'une queue (la suite de la chaîne), on a [M o t | L] . La règle sera :

```
terminal(mot,[mot|L],L).
```

Pour vérifier qu'un nom peut être *souris*, on écrit :

```
n(LO,L) :- terminal(souris,LO,L).
```

Nous reprenons l'exemple de A. GAL, G. LAPALME et P. SAINT-DIZIER[2] pour écrire en PROLOG la grammaire correspondant à l'encadré de la page précédente (grammaire sous forme logique).

```
p(LO,L) :- sn(LO,L1), sv(L1,L).

sn(LO,L) :- det(LO,L1), n(L1,L).

sv(LO,L) :- v(LO,L).
sv(LO,L) :- v(LO,L1), sn(L1,L).

det(LO,L) :- terminal(le,LO,L).
det(LO,L) :- terminal(la,LO,L).

n(LO,L) :- terminal(chat,LO,L).
n(LO,L) :- terminal(souris,LO,L).

v(LO,L) :- terminal(mange,LO,L).
v(LO,L) :- terminal(court,LO,L).

terminal(mot,[mot|L],L).
```

---

(1) A. COLMERAUER a créé PROLOG en 1970.
(2) A. GAL, G. LAPALME et P. SAINT-DIZIER : *PROLOG pour l'analyse automatique du langage naturel*, Ed. Eyrolles, Paris, 1989, pp. 48-78

Si nous posons le but 1 :

```
? - p([le, chat, mange, la, souris], []).
```

PROLOG répond :

```
yes
```

Si nous posons le but 2 :

```
? - p([le, chat, mange, le, souris], []).
```

PROLOG répond :

```
yes
```

Si nous posons le but 3 :

```
? - p([le, chat, court, la, souris], []).
```

PROLOG répond :

```
yes
```

Nous voyons à propos des buts 2 et 3 que notre grammaire accepte une phrase qui a une structure correcte mais ne prévoit pas d'autres contraintes comme l'accord du genre entre l'article et le nom (but 2), et la présence ou l'absence d'un complément d'objet selon que le verbe est transitif ou intransitif (but 3). Pour contrôler ces contraintes, il va falloir coder l'information sur le genre des articles et des noms, ainsi que sur la transitivité des verbes. Nous allons la coder au niveau de la grammaire.

```
p(LO,L) :- sn(LO,L1), sv(L1,L).

sn(LO,L) :- det(genre,LO,L1), n(genre,L1,L).

sv(LO,L) :- v(_,LO,L).
sv(LO,L) :- v(transitif,LO,L1), sn(L1,L).

det(masculin,LO,L) :- terminal(le,LO,L).
det(feminin,LO,L) :- terminal(la,LO,L).

n(masculin,LO,L) :- terminal(chat,LO,L).
n(feminin,LO,L) :- terminal(souris,LO,L).

v(transitif,LO,L) :- terminal(mange,LO,L).
v(intransitif,LO,L) :- terminal(court,LO,L).

terminal(mot,[mot|L],L).
```

L'information *masculin, féminin, transitif, intransitif* est introduite en premier paramètre de *det, n et v*. La mise en correspondance est lancée par *sn* qui force le déterminant et le nom à avoir le même genre et par sv qui vérifie la transitivité. La première règle concernant le syntagme verbal accepte un verbe transitif ou intransitif sans complément

avec l'emploi d'une variable muette notée (_). La deuxième règle pour *sv* exige un verbe transitif. Nous obtenons maintenant :

```
? - p([la, chat, mange, la, souris], []).

no

? - p([le, chat, court, la, souris], []).

no
```

Pour l'instant, nous ne faisons que vérifier si une phrase est conforme à une structure. Il serait intéressant de voir comment on peut obtenir la structure de dépendance entre les constituants de notre phrase d'entrée. PROLOG permet de construire cette structure de façon incrémentielle, grâce à une procédure d'unification.

En PROLOG on peut représenter facilement une structure arborescente avec un *foncteur* qui indique la valeur du nœud et dont les paramètres correspondent aux branches issues du nœud.

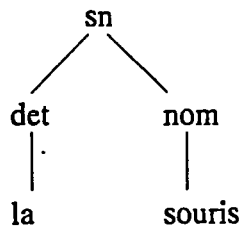

Les termes composés sont notés par un *foncteur* et des *paramètres* qui sont eux-mêmes des termes :

ex. : `sn(det(la),nom(souris))`

Ils représentent une notation pour les arbres. Le *foncteur* étiquette la racine. Les *paramètres* étiquettent les branches.

Soit l'arbre :

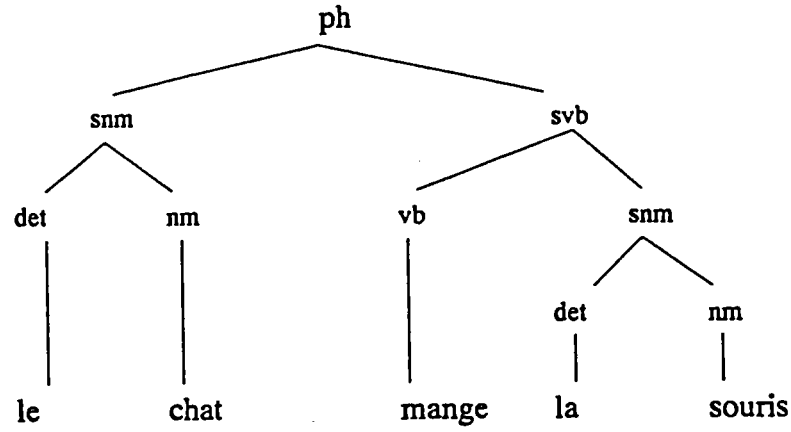

Sa représentation sera :

```
ph(  snm(det(le),
         nm(chat)),
     svb(vb(mange),
         snm( det(la),
              nm(souris))))
```

C'est un paramètre qui porte l'information structurelle et permet de construire l'arbre. Il suffit de donner la forme du foncteur pour qu'un processus d'unification le complète

ou contrôle son adéquation. On obtient la structure d'une phrase avec le foncteur *ph* et en paramètre, les structures du syntagme nominal et du syntagme verbal :

Nous ferons la même chose pour les syntagmes nominal et verbal, ainsi que pour les terminaux. Soit la nouvelle grammaire, constituée uniquement de prédicats d'analyse :

```
p(ph(SN_Struct,SV_Struct,LO,L) :-
sn(SN_Struct,LO,L1),sv(SV_Struct,L1,L).

sn(snm(Det_Struct,N_Struct),LO,L) :-
      det(Det_Struct,Genre,LO,L1), n(N_Struct,Genre,L1,L).

sv(svb(vb(Mot)),LO,L) :- v(vb(Mot,_),_,LO,L).
sv(svb(vb(Mot),SN_Struct),LO,L) :-
v(vb(Mot),transitif,LO,L1),sn(SN_Struct,L1,L).

det(dt(le),masculin,LO,L) :- terminal(le,LO,L).
det(dt(la),feminin,LO,L) :- terminal(la,LO,L).

n(nm(chat),masculin,LO,L) :- terminal(chat,LO,L).
n(nm(souris),feminin,LO,L) :- terminal(souris,LO,L).

v(vb(mange),transitif,LO,L) :- terminal(mange,LO,L).
v(vb(court),intransitif,LO,L) :- terminal(court,LO,L).

terminal(Mot,[Mot|L],L).
```

Il est possible d'ajouter de nombreuses informations en utilisant d'autres prédicats PROLOG et en introduisant de nouveaux paramètres qui véhiculeront de l'information entre les nœuds de l'arbre. On peut alors vérifier d'autres conditions et introduire par exemple un traitement sémantique.

Il reste à contrôler le transfert des listes d'entrée et de sortie entre les prédicats d'une même règle. Ceci est réalisé automatiquement pour les grammaires de métamorphose et les grammaires à clauses définies (DCG). Dans la nouvelle grammaire écrite avec le formalisme des DCG, les parties gauches sont liées aux parties droites par (-->). Le système gère lui-même le passage de la chaîne entre les prédicats. Dans PROLOG, le système transforme la règle, à la lecture, en ajoutant deux paramètres aux prédicats d'analyse. Les prédicats qui ne doivent pas être modifiés sont placés entre accolades. Les terminaux sont entre crochets et la règle `terminal` n'est plus indispensable car prédéfinie par le système. La grammaire DCG s'écrit avec des règles exprimées par des prédicats. Les paramètres assurent le passage de l'information d'un prédicat à l'autre. On pourra ajouter des prédicats PROLOG en les plaçant entre accolades.

La version DCG de notre grammaire sera :

```
p(ph(SN_struct,SV_Struct) --->
sn(SN_Struct),sv(SV_Struct).

sn(snm(Det_Struct,N_Struct)) --->
      det(Det_Struct,Genre), n(N_Struct,Genre).

sv(svb(vb(Mot))) ---> v(vb(Mot,_),_).
sv(svb(vb(Mot),SN_Struct)) --->
v(vb(Mot),transitif),sn(SN_Struct).

det(dt(le),masculin) ---> [le].
det(dt(la),feminin) ---> [la].

n(nm(chat),masculin) ---> [chat].
n(nm(souris),feminin) --_> [souris].

v(vb(mange),transitif) ---> [mange].
v(vb(court),intransitif) ---> [court].
```

Jusqu'ici, les exemples concernent des phrases dont les constituants sont atomiques. Pour l'analyse automatique d'un domaine plus vaste et la construction d'un système évolutif, il convient de dissocier le traitement de la morphologie et celui de la structure de la phrase. On pourra alors enrichir le dictionnaire séparément et considérer le volume des entrées. Une bonne structuration du dictionnaire évitera de conserver toutes les variantes d'une forme (*petit, petite, petits, petites* ou *ai, as, a, avons...*) en lui associant des informations invariantes et des règles de conjugaison, déclinaison ou lemmatisation.

L'analyse de phrases plus complexes telles que les relatives ou les interrogatives fait appel à la notion de *trace*. On part du principe, en effet, qu'une relative est comme une principale dont quelques informations auraient disparu, remplacées par des *traces* qui conservent toutes les propriétés des objets qu'elles remplacent. Pour une analyse correcte, on gardera cette information pour la propager entre les syntagmes, en ajoutant le paramètre `trace` en deuxième argument des prédicats d'analyse. On peut utiliser cette information pour vérifier par exemple l'accord des participes passés.

Nous avons vu que le processus d'unification était très puissant en PROLOG. Dans certains cas, cependant, les structures à unifier n'ont pas la même forme, c'est à dire le même nombre de paramètres et pas dans le même ordre. Si nous reprenons le cas du dictionnaire dans le lequel nous rentrons de nombreux traits, il nous faudra prévoir des valeurs pour des traits non pertinents. L'idéal serait de ne conserver que les traits pertinents et dans un ordre quelconque. Une modification de l'algorithme d'unification permet justement d'"unir" des traits : si un trait se trouve dans deux structures, les valeurs associées devront s'unifier. S'il n'apparaît que dans une, il fera partie de la structure résultante.

En résumé, nous dirons qu'avec PROLOG l'utilisateur dispose d'un formalisme évolué pour :
- décrire et structurer les objets et les relations d'un domaine spécifique,
- en exprimer les connaissances sous forme de faits et de règles,
- poser des questions et exécuter des actions.

PROLOG peut être porté sur tous les systèmes d'exploitation et sur toutes les machines. Si on le compare avec le LISP, un autre langage utilisé en Intelligence Artificielle, il a de gros atouts. Le LISP a été développé à l'époque où l'algorithme était roi.

Il "consomme" beaucoup de logique procédurale. La solution doit avoir été trouvée au préalable. LISP est considéré comme "l'assembleur de l'I.A." parce que justement il suit pas à pas tout raisonnement dans une structure de listes. Pour concevoir un logiciel en LISP, il faut spécifier une série de détails souvent inutiles au regard de l'application. Rien n'est laissé au hasard ou de manière implicite, ce qui peut être un handicap lors de l'élaboration de logiciels complexes. Du reste, les adeptes de LISP utilisent PROLOG en complément car il manquait à LISP un mécanisme de déduciton intégré au sein du langage. On reconnaît à PROLOG les vertus de son système d'unification et son non-déterminisme. Parmi ses avantages par rapport à d'autres langages évolués : l'identité de forme syntaxique entre les données et les programmes de PROLOG en permet une manipulation simple, les paramètres d'entrée-sortie peuvent être incomplètement déterminés pour être affectés ailleurs dans d'autres appels, les appels de règles peuvent générer, à partir de retour arrière des itérations de haut niveau, aucune structure d'enregistrement n'est imposée aussi bien au niveau type que longueur de champ d'enregistrement, PROLOG enfin supprime les boucles, étiquettes, instructions et pointeurs au profit d'une définition du problème qui contient en soi sa propre recherche de la solution.

4.2.2.4 La réalisation de l'ACI

4.2.2.4.1 Matériel utilisé

La mise au point informatique a été réalisée à partir d'un télétype ITT model 43 associé à un modem Anderson Jacobson, en 300 Bauds, sur les ordinateurs du CIRCE, directement ou via TRANSPAC. Les programmes écrits en PL1 Optimizer ont tourné sur IBM 370/168, AMDAHL 470/V7 (5,4 millions d'instructions par seconde) et, depuis 1983, sur NAS 9080 (20 millions d'instructions par seconde), la taille mémoire maximum disponible étant d'environ 5500 K.

4.2.2.4.2 Données

En l'absence de grands dictionnaires, les données relatives à une langue (source ou cible) n'occupent jamais plus de 128 K, ce qui limite le temps calcul et la présence de mémoires de masse. Elles sont rangées dans des fichiers séquentiels ou partitionnés qui n'excèdent jamais 1000 entrées. Le fonctionnement automatique du système impose une gestion automatique de tous les fichiers d'entrée et de sortie. C'est la raison pour laquelle les premières lignes indiquent toujours le nombre d'enregistrements, le LRECL (longueur de l'enregistrement logique) et le BLKSIZE (taille du bloc). Les enregistrements ont un RECFM (format et caractéristiques des enregistrements) VB, c'est à dire qu'ils sont de longueur variable et bloqués.

```
listds .morphal1
ASU4416.DIMON.MORPHAL1
--RECFM-LRECL-BLKSIZE-DSORG
  VB     30     6334     PO
--VOLUMES--
  RES305
READY
```

```
e .morphal1(faible) data
E
1 '10 80
00010 *.MORPHAL1(FAIBLE)
00020 811
00030 0030
00040 6334
00050 100ACHT
00060 100A*CHT
00070 100A*CHZ
00080 10±ACKER
end s
READY
```

Le PL1 permet de les utiliser avec une extrême rapidité grâce aux variables et aux structures basées accompagnées de l'attribut REFER. Cette technique vaut pour les fichiers de traitement que les programmes taillent sur mesure en calculant les paramètres cités plus haut et en les insérant en début de fichier. Cette démarche permettra d'utiliser un fichier sortie (résultats) en entrée pour l'exécution d'un autre programme, de façon automatique. C'est ainsi qu'une modification des données n'entraîne qu'une réécriture des premiers enregistrements et aucune intervention sur les programmes, ces derniers n'étant retouchés qu'à l'apparition de problèmes imprévus.

4.2.2.4.3 Programmes

Nous utilisons le langage PL1 (4ème version). Plusieurs éléments ont guidé notre choix :

• C'est un des rares langages qui permettent de donner des caractéristiques de fichier et même de les calculer, contrairement à d'autres où l'on ne peut agir qu'au niveau du langage de gestion.
• A la maîtrise de la création des fichiers de sortie s'ajoute la maîtrise des chaînes de caractères. S'il n'a pas été conçu pour la manipulation de textes en langue naturelle, PL1 offre la possibilité de manipuler des chaînes de 32767 caractères et les opérations sur ce type de chaîne sont suffisamment développées pour que ce domaine puisse être un de ses domaines d'application. Ceci veut dire que nous n'en utilisons qu'une partie réduite :
• variables statiques, automatiques, contrôlées;
variable basée (avec la version 4 de PL/1), pointeurs, variables pointées, tableaux et structures : structures basées avec option REFER, variables PIC
• fonctions de manipulation de chaîne
• fichiers STREAM RECORD avec option ENV, pour imposer les caractéristiques calculées aux DATASETS correspondants
• bloc, procédure et fonction récursive ou non, fonction incorporée, procédure paramétrée avec des pointeurs
• macro-instructions

Les programmes sont courts (400 lignes en moyenne). On peut en contrôler facilement le fonctionnement et ils occupent moins de place. Les lectures de fichier se font par variables basées, ce qui nous ramène presque au niveau du langage machine.

4.2.2.4.4 Procédures

Afin de disposer d'une grande souplesse dans l'enchaînement des programmes nous n'utilisons pas le JCL (langage de contrôle des travaux) dont la syntaxe nous semble assez contraignante, mais la procédure.

La procédure de commandes est un fichier dont les enregistrements sont composés de commandes, sous-commandes ou d'instructions de contrôle. Lors de son exécution, chaque enregistrement correspond à l'image d'une ligne de terminal. La ligne est alors traitée comme si elle avait été entrée directement. Les commandes sont liées au système d'exploitation (TSO sous-système de MVS) :

- allocation des fichiers d'entrée et de sortie (mise en place des fichiers physiques par DATASET, des fichiers logiques par FILE)
- appel des modules chargeables
- destruction des fichiers
- mesure du temps calcul
- désallocation

- vérification de l'existence des fichiers et tassement lorsque nécessaire.

Cette très grande souplesse, alliée à la simplicité d'écriture, permet de contrôler les temps de calcul pour chaque programme et d'en enchaîner une infinité, en détruisant les fichiers temporaires qui ne sont plus utiles.

4.3 La structure de l'ACI

4.3.1 La mise en forme

4.3.1.1 Textes

Nous disposons de textes d'essai en allemand, néerlandais, luxembourgeois et anglais.

Allemand

1 - *Umweltplanung in der Industriegesellschaft: Lösungen und ihre Probleme.* de Konrad STAHL et Gerhard CURDES, ROWOHLT Taschenbuch (1970), 28 000 mots.

2 - *Leistungsreaktortypen*: document AG.TELEFUNKEN (50 000 mots)

3 - *Differenzverstärker*: document DRET (9 000 mots)

4 - *Hirnfunktion und Hirndurchblutung*: de Niels LASSEN, David INGVAR et Eril SKINHØT: (4 800 mots)

5 - *Brennstoffzellenkraftwerke* de Arnold P. FICKETT (3 500 mots)

Néerlandais

- *Kernenergie in de lage landen* de J.A. GOEDKOOP: (45 000 mots)

Luxembourgeois

- *D'Reform vun der Létzebuerger Ekonomie* de J.P. SCHNEIDER: (50 000 mots)

Anglais

- *Fuel-Cell Power Plants* de Arnold FICKETT : (3 800 mots)

4.3.1.2 Schéma d'ensemble

Les exemples que nous proposerons pour l'allemand seront tous extraits du même texte, dans un souci de cohérence, sauf en de rares occasions où nous serons obligé de faire appel à d'autres sources. Le choix du texte n°5 nous semble s'imposer, tant il est riche en difficultés de toutes sortes.

Avant d'examiner le niveau Ø dans le détail, nous schématiserons dans la page qui suit, l'enchaînement des divers modules (en majuscule) avec les fichiers d'entrée et de sortie (en minuscule). Les ensembles importants, pour plus de clarté, figurent dans des cadres à trame grisée. Ils seront "décortiqués" par la suite, VERBAL dans le chapitre 4.3.6, MOTCOMP et MOTCOMPA dans les chapitre 4.4.2, 4.4.3 et 4.4.4, SYNTAX enfin dans le chapitre 4.5.

Schéma du système

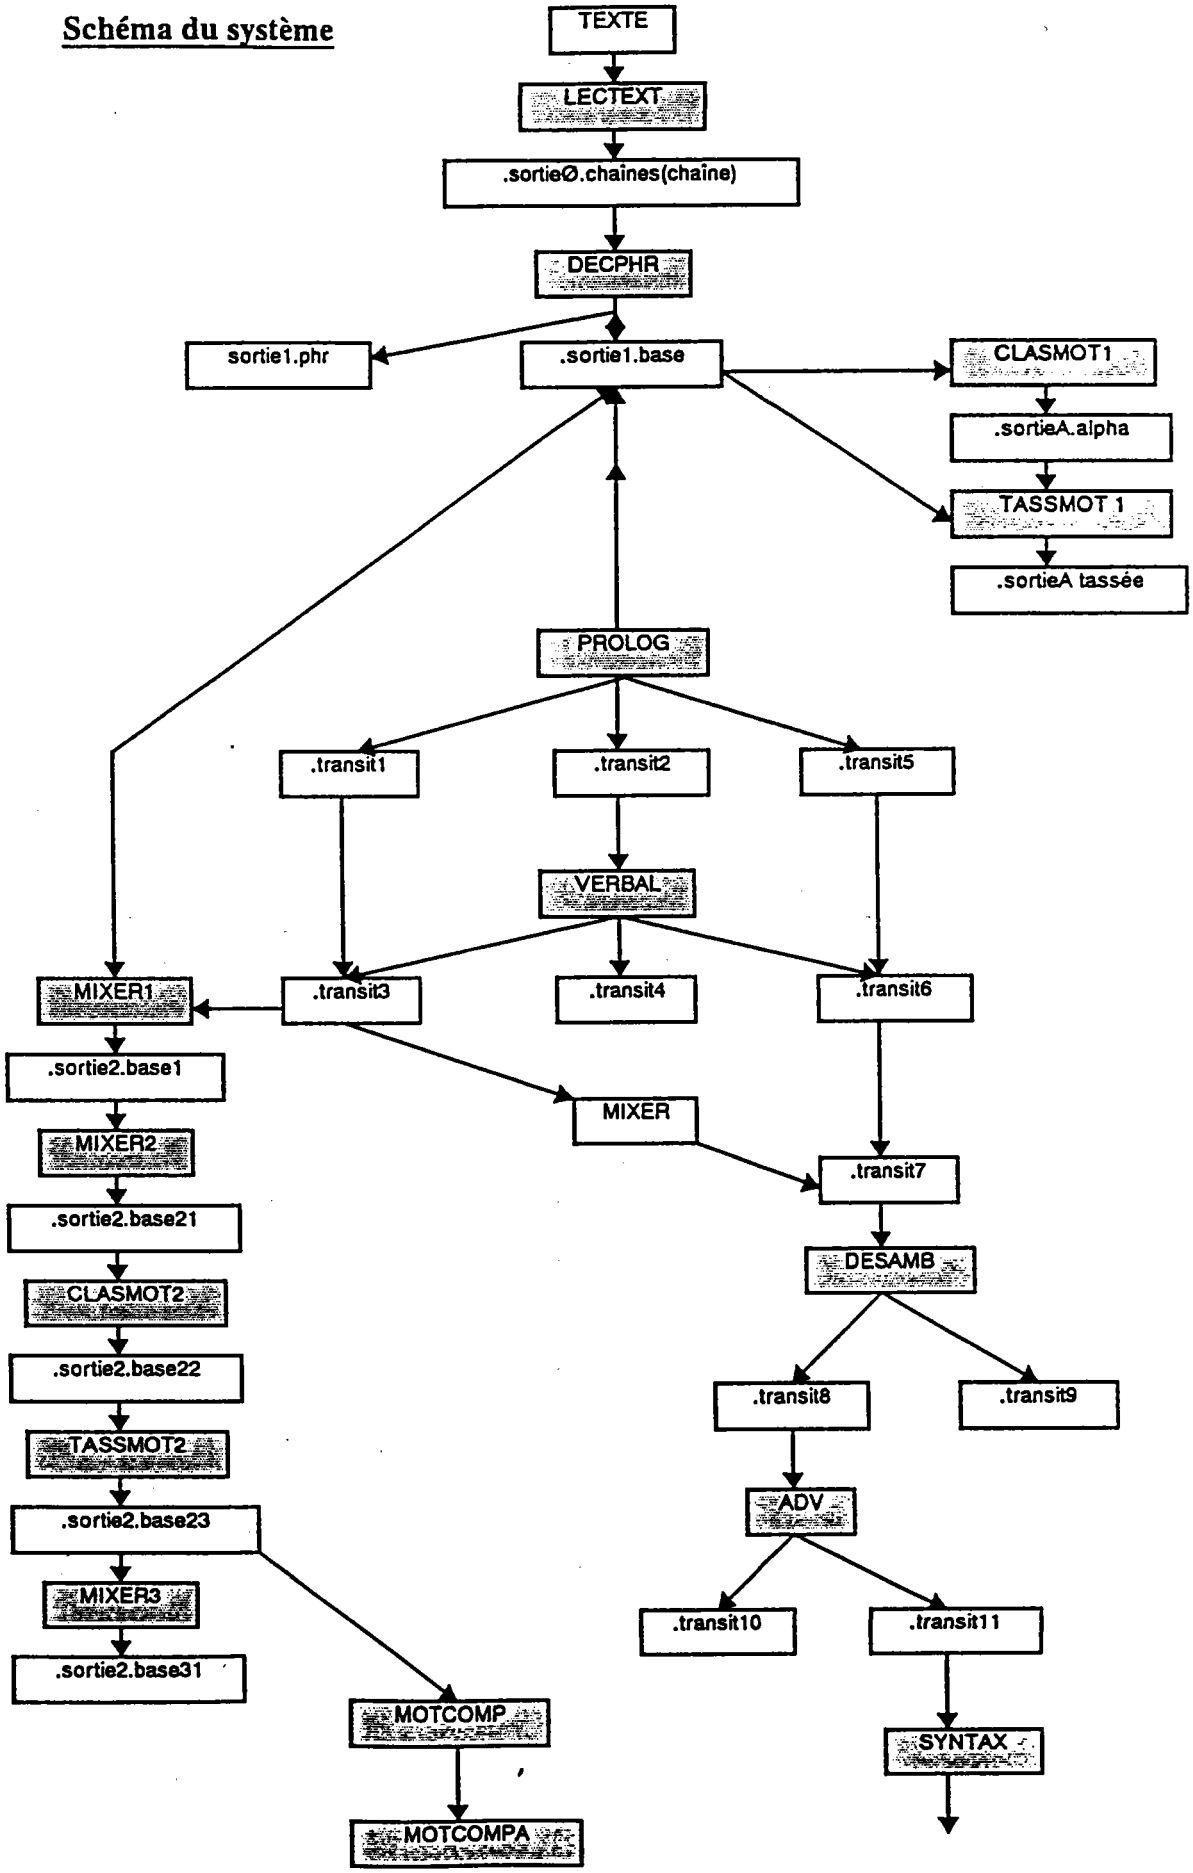

4.3.1.3 Procédure générale

Comme l'indique le tableau de la page 178, le niveau 0 correspond à la préparation du texte (LECTEXT et DECPHR), au codage des mots-outils, des nombres en lettres ou en chiffres, des symboles et des noms autres qu'en début de phrase (PROLOG), à l'élaboration du lexique tassé du texte proposé en option (CLASMOT1 et TASSMOT1), à l'analyse du verbe (FILTRAL, VERBAL1, VERBAL2), à l'étude des adjectifs/adverbes (ADV) et à la désambiguïsation de la majuscule en début de phrase (DESAMB).
La procédure qui assure le fonctionnement de ce niveau 0 s'appelle PDROC(CRJF). Elle contient plus de 600 lignes et enchaîne les programmes mentionnés p. 178, présents sous forme de module chargeable. Le fichier de départ est un des membres du fichier partitionné .TEXALL, .TEXOLL ou .TEXANG. Le fichier d'arrivée est .TEXALL1.SORTIE2.BASE23, .TEXOLL1.SORTIE2.BASE23 ... (selon la langue choisie), pour le traitement ultérieur des mots composés, .TRANSIT11 pour l'analyse syntaxique.

.PDPROC(CRJF) :

De manière forfaitaire, le système alloue quinze fichiers, quelle que soit la longueur du texte :

```
00100 PROC 0
00200 WRITE
00300 D'INTERPRETATION
00400 WRITE
00500 ****************
00600 CONTROL END(STOP)
00700 WRITE FONCTIONNEMENT DU SYSTEME CRJF EN DATE DU &SYSDATE, &SYSTIME
00800 WRITE CONTROLE DU TEMPS DE SESSION ET DU TEMPS CPU :
00900 TIME
01000 WRITE CHOISIR LA LANGUE-SOURCE : ECRIRE ALL POUR ALLEMAND, ...


05400 WRITE AUCUNE ANALYSE N'A ETE FAITE SUR CE TEXTE. LE SYSTEME SE PLACE +
05500 DONC AU NIVEAU 0
05600 GOTO ETIQ15
05700 STOP
05800 ETIQ9: DO
05900 WRITE LA LECTURE INITIALE DU TEXTE A DEJA ETE FAITE. LE SYSTEME SE +
06000 PLACE DONC AU NIVEAU 1
06100 GOTO ETIQ16
06200 STOP
06300 ETIQ10: DO
06400 WRITE LA MISE EN FICHIER DU TEXTE ET SON ANALYSE 'VERBE' SONT +
06500 TERMINEES. LE SYSTEME SE PLACE DONC AU NIVEAU 2
06600 GOTO ETIQ16A
06700 STOP
06800 ETIQ11: DO
06900 WRITE LES OPERATIONS DU NIVEAU 2 SONT TERMINEES. LE SYSTEME SE PLACE +
07000 AU NIVEAU 3
07100 GOTO ETIQ18
07200 STOP
07300 ETIQ15: DO
07400 FREEALL
07500 WRITE ALLOCATION INITIALE DES FICHIERS
07600 LISTA STATUS
07700 WRITE **FONCTIONNEMENT DE LA LECTURE INITIALE
07800 WRITE ALLOCATION DU FICHIER-ENTREE ET DES 15 FICHIERS-SORTIE -
07900 FORFAITAIRES
```

Il appelle les programmes responsables de la mise en forme du texte :

```
08000 ALLOC DATASET(.TEX&A.(&B.)) FILE (ENTREE)
08100 WRITE ALLOCATION DE DATASET(.TEX&A.(&B.)) SUR FILE (ENTREE)
08200 ALLOC DATASET(.&B..SORTIE0.CHAINES) NEW DIR(5) SPACE (4,1) TRACKS
08300 SET N=1
08400 DO WHILE &N<16
08500 ALLOC DATASET(.&B..SORTIE0.CHAINES(CHAINE&N.)) FILE (SORTIE&N.)
08600 WRITE ALLOCATION DE DATASET(.&B..SORTIE0.CHAINES(CHAINE&N.)) SUR FILE
08700 (SORTIE&N.)
08800 SET N=&N+1
08900 STOP
09000 CALL .CHARGE(LECTEXT)
09100 FREEALL
09200 WRITE CHAINES DU TEXTE ETUDIEES :
09300 LISTM .&B..SORTIE0.CHAINES
09400 XPRESSION .&B..SORTIE0.CHAINES
09500 SPACE .&B..SORTIE0.CHAINES
09600 GOTO ETIQ16
09700 STOP
09800 ETIQ16: DO
09900 WRITE **LECTURE INITIALE TERMINEE
10000 ALLOC DATASET(.&B..SORTIE0.CHAINES(CHAINE1)) FILE (ENTREE)
10100 ALLOC DATASET(.&B..SORTIE1.BASE) NEW SPACE(4,1) TRACKS +
10200 FILE (SORTIE1)
10300 ALLOC DATASET(.&B..SORTIE1.PHR) NEW SPACE(4,1) TRACKS FILE (SORTIE2)
10400 CALL .CHARGE(DECPHR)
10500 RLSE .&B..SORTIE1.BASE
10600 SPACE .&B..SORTIE1.BASE
10700 RLSE .&B..SORTIE1.PHR
10800 SPACE .&B..SORTIE1.PHR
10900 FREEALL
```

Intervient ensuite le début du traitement du verbe :

```
11000 ALLOC DATASET(.VERBE(ENDUNG)) FILE (PAENDUN)
11100 ALLOC DATASET(.VERBE(VERB)) FILE (PAVER)
11200 ALLOC DATASET(.VERBE(NOVERB)) FILE (PANOVER)
11300 ALLOC DATASET(.VERBE(PREFI)) FILE (PAPREFI)
11400 ALLOC DATASET(.VERBE(KOLL)) FILE (PAKOLL)
11500 ALLOC DATASET(.VERBE(FAIBLE)) FILE (PAFAIBL)
11600 ALLOC DATASET(.VERBE(FORT)) FILE (PAFORTS)
11700 ALLOC DATASET(.TEX&A.(&B.)) FILE (RALLE)
11800 ALLOC DATASET(.&B..SORTIE1.VERBE) NEW SPACE (3,1) TRACKS -
11900       FILE (SORTIE)
12000 CALL .CHARGE(VERBAL)
12100 RLSE .&B..SORTIE1.VERBE
12200 SPACE .&B..SORTIE1.VERBE
12300 FREEALL
12400 GOTO ETIQ16A
12500 STOP
12600 ETIQ16A: DO
12700 WRITE ** VOULEZ-VOUS EDITER UN LEXIQUE ALPHABETIQUE ET UN LEXIQUE +
12800 TASSE (DE FACON SPECIALE) DES MOTS DE CE TEXTE ?
12900 WRITE ** ATTENTION...CES LEXIQUES NE SERONT PAS UTILISES PAR LE +
13000 SYSTEME ET, DE PLUS, COUTENT ASSEZ CHER.
13100 WRITE ** REPONDRE PAR 'OUI' OU PAR 'NON' (SANS METTRE DE QUOTES).
```

Programmes de tri et de tassement pour l'utilisateur qui demande un lexique :

```
14000 TIME
14100 CALL .CHARGE(CLASMOT1)
14200 FREEALL
14300 ALLOC DATASET(.&B..SORTIE1.BASE) FILE (ENTREE1)
14400 ALLOC DATASET(.&B..SORTIEA.ALPHA) FILE (ENTREE2)
14500 ALLOC DATASET(.&B..SORTIEA.TASSEE) NEW SPACE (4,1) TRACKS
14600       FILE (SORTIE)
14700 CALL .CHARGE(TASSMOT1)
14800 TIME
```

Programmes qui préparent le fichier d'entrée du module MOTS COMPOSES :

```
16500 CALL .CHARGE(MIXER1)
16600 RLSE .&B..SORTIE2.BASE1
16700 SPACE .&B..SORTIE2.BASE1
16800 FREE DATASET(.&B..SORTIE2.BASE1)
16900 ALLOC DATASET(.&B..SORTIE2.BASE21) NEW SPACE (1,1) TRACKS +
17000       FILE (SORTIE2)
17100 CALL .CHARGE(MIXER2)
17200 RLSE .&B..SORTIE2.BASE21
17300 SPACE .&B..SORTIE2.BASE21
17400 FREE DATASET(.&B..SORTIE2.BASE21)
17500 ALLOC DATASET(.&B..SORTIE2.BASE21) FILE (ENTREE6)
17600 ALLOC DATASET(.&B..SORTIE2.BASE22) NEW SPACE (2,1) TRACKS +
17700       FILE (SORTIE4)
17800 CALL .CHARGE(CLASMOT2)
17900 FREE DATASET(.&B..SORTIE2.BASE22)
18000 ALLOC DATASET(.&B..SORTIE2.BASE22) FILE (ENTREE7)
18100 ALLOC DATASET(.&B..SORTIE2.BASE23) NEW SPACE (2,1) TRACKS +
18200       FILE (SORTIE5)
18300 CALL .CHARGE(TASSMOT2)
18400 RLSE .&B..SORTIE2.BASE22
18500 RLSE .&B..SORTIE2.BASE23
18600 SPACE .&B..SORTIE2.BASE22
18700 SPACE .&B..SORTIE2.BASE23
18800 ALLOC DATASET(.&B..SORTIE2.BASE31) NEW SPACE (2,1) TRACKS +
18900       FILE (SORTIE3)
19000 CALL .CHARGE(MIXER3)
```

4.3.1.4 LECTEXT, DECPHR

Sans poursuivre l'examen de la procédure et en laissant de côté pour l'instant ce qui concerne **PROLOG, VERBAL, ADV** et **DESAMB** nous allons observer les transformations successives que subit la forme du texte à l'aide de quelques exemples suivis d'un rapide commentaire.
Pour tenir compte de toutes les informations que nous apporte le texte, nous transcrivons les éléments que l'oeil transmet au cerveau comme étant différents de l'écriture, et uniquement ceux-là. Il n'y a pas de **"préédition"**. Le texte entré en machine est la réplique de l'original, aux éléments de simulation près.

Texte allemand étudié, sous sa forme originale :

BRENNSTOFFZELLEN-KRAFTWERKE

Von Arnold P. Fickett

Brennstoffzellen wandeln die chemische Energie eines Brennstoffs direkt in Energie um. Sie emittieren weder Schmutz noch Schadstoffe und haben, wenn man ihre Abfallwärme nutzt, einen hohen Wirkungsgrad. Gegenwärtig wird untersucht, ob sie auch im großen Maßtab wirtschaftlicher Arbeiten.

Im nächsten Jahrzehnt wird man von einem Elektrizitätswerk fordern, daß es einen hohen Wirkungsgrad hat, möglichst wenig Schmutz emittiert, keinen Lärm verursacht und rasch zu installieren ist. Ein vielversprechender Kandidat ist die Brennstoffzelle.
Eine Brennstoffzelle wandelt die chemische Energie eines Brennstoffs direkt, das heißt ohne den Umweg über die Wärme, in Elektrizität um. Schon 1839 erfand Sir William Grove, ein englischer Jurist, das Gerät, aber es dauerte lange, ehe es zu seinem Recht kam. Brennstoffzellen versorgten die Gemini-und Apollo-Raumschiffe mit Energie und fanden damit eine ebenso exotische wie teure Anwendung. Heute gibt es Brennstoffzellen in verbesserten und tausendmal größeren Versionen, und es scheint, als sei das Stadium erreicht, in dem man von ihnen einen nennenswerten Beitrag zur öffentlichen Elektrizitätsversorgung erwarten kann.

Eine Brennstoffzelle (Bild 2) besteht aus zwei Elektroden - einer positiven (der Kathode) und einer negativen (der Anode) - , die durch einen Elektrolyten getrennt sind. Im Elektrolyten können Ionen (positiv oder negativ geladene Atome, Moleküle oder Molekülteile) transportiert werden, nicht aber die negativ geladenen Elektronen, die für den Elektrizitätstransport in metallischen Leitern verantwortlich sind. Der Brennstoff (beispielsweise Wasserstoff) wird der Anode zugeführt, während man die Kathode mit dem Oxidationsmittel (beispielsweise Sauerstoff aus der Luft) versorgt. An der Anode bewirkt ein Katalysator die Aufspaltung der Wasserstoff-Moleküle in Wasserstoff-Ionen (H^+) und Elektronen (e). Da Anode und Kathode porös sind und der Elektrolyt aus Phosphorsäure besteht, können die Wasserstoff-Ionen von der Anode zur Kathode wandern, wo sie sich mit dem Sauerstoff und den über den Stromkreis von der Anode zur Kathode fließenden Elektronen zu Wasser (H_2O) vereinigen, das die Brennstoffzelle verläßt. Im Effekt "verbrennt" die Zelle also Wasserstoff mit Sauerstoff zu Wasser, setzt die dabei freiwerdende Energie aber nicht - wie bei einer normalen Verbrennung - vollständig in Wärme um, sondern verwendet sie zum Teil, um Elektronen durch den Stromkreis von der Anode zur Kathode zu treiben, das heißt einen elektrischen Strom zu erzeugen, der eine Lampe zum Leuchten bringen oder einen Elektromotor antreiben kann.

Die Art des Elektrolyten hängt von der chemischen Reaktion ab, mit der die Brennstoffzelle arbeitet, denn die Natur dieser Reaktion bestimmt, welches Ion von der Anode zur Kathode gelangen muß. Saure Elektrolyte transportieren Wasserstoff-Ionen (H^+), in alkalischen Elektrolyten wandern Hydroxid-Ionen

(OH-). Carbonat-Ionen (CO32-) brauchen ein Salz der Kohlensäure als Elektrolyt, und um Sauerstoff-Ionen (O2-) zu transportieren, verwendet man ein festes Oxid.
Die Gleichspannung, die eine Brennstoffzelle erzeugen kann, hängt gleichfalls von der Art der chemischen Reaktion ab, aus der sie ihre Energie gewinnt. Eine mit Wasserstoff und Sauerstoff betriebene Zelle ist theoretisch in der Lage, bei normalem Druck und normaler Temperatur eine Spannung von 1,23 Volt zu liefern. Tatsächlich erhält man infolge von Energieverlusten in der Zelle jedoch nur zwischen 0,6 und 0,85 Volt. Die Stromstärke, also die Zahl der in der Zeiteinheit zur Verfügung gestellten Elektronen, ergibt sich aus der Geschwindigkeit der chemischen Reaktion und aus der Größe der Oberflächen von Anode und Kathode.
Eine einfache Brennstoffzelle erhält man schon, wenn man zwei Kohlestäbe, die etwas Platin als Katalysator enthalten, in ein Gefäß mit Schwefelsäure taucht und den einen Stab mit Wasserstoff, den anderen mit Sauerstoff umspült. Die Schwefelsäure wirkt als Elektrolyt, und die Reaktion des Wasserstoffs mit dem Sauerstoff zu Wasser erzeugt in der in Bild 2 gezeigten Weise eine Gleichspannung von etwas weniger als einem Volt. Man kann diese Spannung messen, wenn man die Kohlestäbe außerhalb des Gefäßes durch ein Voltmeter verbindet.
Natürlich eignet sich diese einfache Anordnung nicht für technische Zwecke : die Oberfläche der Kohlestäbe ist zu klein, Schwefelsäure ist ein unpraktischer Elektrolyt, und offene Gefäße lassen sich nicht raumsparend zu Blöcken von Brennstoffzellen zusammenfassen. Man baut Brennstoffzellen daher so, daß man den Elektrolyten als dünne, flache Schicht zwischen zwei gleichfalls flache, porös gestaltete und mit dem Katalysator imprägnierte Elektroden packt. In dieser Form kann man sie zu hunderten übereinanderstapeln (Bild 1). Die Spannung, die ein solcher Stapel liefert, ergibt sich, wenn man die Spannung der Einzelzelle mit der Anzahl der Zellen multipliziert.

Zu einem Brennstoffzellen-Kraftwerk gehören neben zahlreichen Brennstoffzellen-Stapeln noch zwei weitere Anlagen (Bild 3) : ein Brennstoff-Aufbereiter (auch als Reformer bezeichnet) hat die Aufgabe, aus einem billigen und leicht speicherbaren Brennstoff, beispielsweise Kohle, den Brennstoff zu erzeugen (etwa ein wasserstoffreiches Gas), mit dem die Zellen arbeiten können, und der Wechselrichter wandelt die von den Zellen gelieferte Gleichspannung in Wechselspannung um, die dann dem öffentlichen Elektrizitätsnetz zugeführt werden kann.

Der Wirkungsgrad eines Brennstoffzellen-Kraftwerks, das heißt der Prozentsazt der im angelieferten Brennstoff enthaltenen Energie, der in Form von elektrischer Energie schließlich dem öffentlichen Elektrizitätsnetz zu Verfügung gestellt wird, ergibt sich auf etwa fünf Prozent genau aus der empirischen Formel n=59xV, wobei V die von der einzelnen Zelle gelieferte Spannung ist. Das für den Bau eines Brennstoffzellen-Kraftwerks erforderliche Kapital besteht nur zu zwölf bis dreiaig Prozent aus Kosten für Brennstoffzellen-Stapel und Wechselrichter. Den Rest braucht man für den Bau der Anlage, die den Brennstoff aufbereitet, wobei die Kosten mit Kohle als primärem Brennstoff höher sind als bei Verwendung von Erdöl. Die meisten Entwicklungsarbeiten verfolgen gegenwärtig das Ziel, Leistung, Zuverlässigkeit und Stabilität der einzelnen Brennstoffzelle zu steigern und deren Kosten zu senken.

Brennstoffzellen unterscheiden sich in ihrer Arbeitstemperatur sowie im Elektrolyten, im Brennstoff und im Oxidationsmittel. Nicht alle denkbaren Kombinationen dieser vier Merkmale sind praktisch brauchbar, denn mit der Wahl des Elektrolyten trifft man eine Vorentscheidung hinsichtlich der anderen Faktoren und umgekehrt. So kann man mit Phosphorsäure als Elektrolyten nur zwischen 150 und 200 Grad Celsius arbeiten. Unterhalb dieses Temperaturbereiches hat die Phosphorsäure eine zu geringe Leitfähigkeit, und oberhalb greift sie das Elektrodenmaterial an.

Eine Brennstoffzelle mit einer Carbonat-Schmelze als Elektrolyten braucht eine Arbeitstemperatur zwischen sechshundert und siebenhundert Grad Celsius und einen aus Kohlenstoffoxiden und Wasserstoff bestehenden Brennstoff. Mit Kaliumhydroxid als Elektrolyten, legt man sich auf eine Temperatur zwischen 50 und 150 Grad Celsius fest und muß Brennstoff und Oxidationsmittel von Kohlenstoffoxiden freihalten, da sich aus dem Kaliumhydroxid sonst Kaliumcarbonat bildet, das die Leistung der Zelle drastisch verringert. Brennstoffzellen mit Kaliumhydroxid als Elektrolyten, reinem Wasserstoff als Brennstoff und reinem Sauerstoff als Oxidationsmittel haben sich in Raumschiffen bewährt, aber ihre irdische Verwendung scheitert am Preis des reinen, das heißt von Kohlenstoffoxiden freien Wasserstoffs und Sauerstoffs.

Brennstoffzellen mit Schwefelsäure, Sulfonsäuren oder festen Polymeren als Elektrolyten hängen davon ab, daß der Elektrolyt den richtigen Wassergehalt hat. Man muß sie unterhalb hundert Grad Celsius betreiben, wenn man Luft als Oxidationsmittel ver wendet, denn anderenfalls nimmt der in der Luft enthaltene Stick stoff, der die Brennstoffzelle unverändert verläßt, zuviel Wasserdampf mit sich. bei dieser Temperatur erreicht die Brennstoffzelle aber nicht den Wirkungsgrad, den sie in einem an das öffentliche Elektrizitätsnetz angeschlossenen Kraftwerk haben muß.

In erster Linie interessiert man sich heute für Brennstoffzellen, die mit Phosphorsäure als Elekrolyten arbeiten, beschäftigt sich in kleinerem Umfang auch mit Carbonat-Schmelzen als Elektrolyten und untersucht feste Elektrolyte, die Sauerstoff-Ionen transportieren und Arbeitstemperaturen um tausend Grad Celsius verlangen, doch sind Brennstoffzellen auf dieser Basis vorerst noch nicht praktikabel.

Die Vorteile der Brennstoffzelle liegen in ihrem Wirkungsgrad, ihren umweltschonenden Eigenschaften und in der Tatsache, daß sie sich wie ein Baustein verwenden läßt, um beliebig große Systeme zusammenzusetzen. Ihr Wirkungsgrad, bleibt zwischen 25 und 100 Prozent ihrer Nennleistung nahezu unverändert (Bild 4), was beträchtliche Einsparrungen an Brennstoff ermöglicht, wenn man sie einsetzt, um die täglichen Schwankungen des Elektrizitäts-bedarfs auszugleichen. Man erkennt das aus folgendem Beispiel (Bild 4) : Ein herkömmliches mit Öl beheiztes Kraftwerk, in dem die bei der Verbrennung gewonnene Wärme eine Gasturbine treibt, deren Abwärme zum Betrieb einer Dampfturbine dient, braucht ungefähr 9000 Kilojoule Wärmeenergie, um eine Kilowattstunde elektrische Energie zu erzeugen, wenn es bei seiner Nennleistung arbeitet. Wird es - bei Lastabhängigem Betrieb - nur zur 40 Prozent seiner Nennleistung genutzt, so verbraucht es fast 12000 Kilojoule, um eine Kilowattstunde zu liefern. Ein Brennstoffzellen-Kraftwerk ver braucht dagegen etwa 9500 kilojoule pro Kilowattstunde bei voller Nennleistung und 9800 Kilojoule pro Kilowattstunde bei vierzig Prozent seiner Nennleistung. Es ist also besonders wirtschaftlich, ein normales Wärmekraftwerk so auszulegen, daß es ungefähr den durschnittlichen Elektrizitätsbedarf befriedigt, wenn es bei voller Nennleistung läuft, und es mit einem Brennstoffzellen-Kraftwerk zu koppeln, das lastabhängig betrieben wird und für den Spitzenbedarf aufkommt. In einem Brennstoffzellen-Kraftwerk erzeugt nur die Anlage, die der Brennstoff-Aufbereitung dient, umweltbelastende Abgase. Mit Öl oder Kohle als primären Brennstoffen sind das vor allem Schwefeldioxid und Stickstoffoxid, doch liegt die Schwefeldioxid-Emission besonders niedrig, weil die Brennstoffzelle gegen Schwefelverbindungen empfindlich ist, so daß diese in der Brennstoff-Aufbereitungsanlage entfernt werden müssen. Ein Brennstoffzellen-Kraftwerk sollte kaum Lärm verursachen und bei Außentemperaturen bis zu 35 Grad Celsius auch kein Kühlwasser brauchen. Es müßte also möglich sein, solche Kraftwerke in unmittelbarer Nähe des Verbrauchers zu installieren, was sowohl den Bau neuer Überlandleitungen als

auch die mit dem Elektrizitätstransport über große Entfernungen verbundenen Energieverluste vermeidet.

Da sich Brennstoffzellen bausteinartig zu Kraftwerken zusammensetzen lassen, kann man sie in einer Fabrik in großen Mengen produzieren. Die Größe eines aus ihnen konstruierten Kraftwerks kann sich nach dem Elektrizitätsbedarf des Versorgungsgebietes richten und mit diesem wachsen. Überdies vermindert die Dezentralisierung der Elektrizitätsversorgung durch den Bau lokaler Brennstoffzellen-Kraftwerke die Anfälligkeit des Systems gegen Störungen.

Mit Brennstoffzellen sollte es also möglich sein, ein abgestuftes System der Elektrizitätsversorgung aufzubauen : Verhältnismäßig keine Anlagen (mit Leistungen zwishen 25 und 200 Kilowatt) könnten in großen Wohn- oder Bürogebäuden stehen, mit Erdgaz arbeiten und sowohl elektrische Energie erzeugen als auch Wärmeenergie (in Form von Abfallwärme). Sie würden für beide Energieformen zusammen nicht mehr Brennstoff verbrauchen als gegenwärtig für Heizzwecke allein benötigt wird und ihr wirkungsgrad sollte nahezu hundert Prozent betragen.

Größere Anlagen mit Leistungen zwischen 5 und 25 Megawatt wären an verschiedenen Stellen eines Elektrizitätsnetzes zu installieren, um Schwankungen des Elektrizitätsbedarfes aufzufangen. Wenn mann in der Lage, auch die Abfallwärme dieser Anlagen nutzbringend zu verwenden, ließen sich Wirkungsgrade über achtzig Prozent (bezogen auf verbrauchten Brennstoff) erreichen.

Erst in fernerer Zukunft wird man Brennstoffzellen mit Kohlever gasungsanlagen kombinieren, um zu Kraftwerken von 150 bis 600 Megawatt Leistung zu kommen, für die Kohle der primäre Brennstoff ist. Bezogen auf den Heizwert der verbrauchten Kohle sind hier Wirkungsgrade über 45 Prozent zu erwarten. Die mit Phosphorsäure als Elektrolyten arbeitende Brennstoffzelle ist am weitesten fortgeschritten. Sie besteht aus einer dünnen, porösen und mit konzentrierter Phosphorsäure getränkten Platte, die zwischen zwei porösen Kohle-Elektroden liegt. Letztere enthalten als Katalysator zwischen 2,7 und 8 Gramm Platin pro Quadratmeter. Die Phosphorsäure-Zelle arbeitet bei 150 bis 190 Grad Celsius, erzeugt eine Gleichspannung von 0,64 Volt und hat eine Leistungsdichte von 1,1 bis 2,2 Kilowatt pro Quadratmeter. Man schätzt, daß Kraftwerke, die aus solchen Zellen bestehen, 1980 in den USA für 350 Dollar pro Kilowatt produziert werden können, sofern sich die Gesamtproduktion von Brennstoffzellen auf 500 Megawatt pro Jahr beläuft. Dieser Preis wäre mit den Kosten anderer Stromerzeuger für lastabhängigen Betrieb vergleichbar. Kleine Stapel von Phosphorsäure-Zellen haben heute schon viele tausend betriebsstunden erreicht, aber die über vierzigtausend Stunden (viereinhalb Jahre) gehende Dauerprüfung eines großen Stapels steht noch aus.

Die Entwicklung von Brennstoffzellen, die mit einer Carbonat-Schmelze als Elektrolyten arbeiten, ist um mindestens fünf Jahre weiter zurück als die Entwicklung der Phosphorsäure-Zellen. Eine dünne Schicht aus geschmolzenem Carbonat und inertem Füllmaterial liegt hier zwischen zwei Elektroden aus porösem Nickel. Die Arbeitstemperatur beträgt 650 Grad Celsius, und unter diesen Bedingungen verlaufen die Reaktionen an den Elektroden so schnell, daß man keine Katalysatoren braucht. An der Kathode bildet sich aus Nickel und Sauerstoff Nickeloxid, das als das eigentliche Kathodenmaterial wirkt, während die Anode unverändert bleibt. Carbonat-Zellen erzeugen eine Spannung von 0,785 Volt und haben Leistungsdichten zwischen 1,1 und 1,3 Kilowatt pro Quadratmeter. Die höhere Spannung und die Unempfindlichkeit gegenüber Kohlenstoffoxiden sind Vorteile der Carbonat-Zellen. Eine kleine Zelle hat schon mehr als 14000 Betriebsstunden hinter sich, und ein aus 19 Zellen von je ungefähr 0,1 Quadratmeter Fläche bestehender Stapel arbeitet seit über 1400 Stunden.

Trotz dieser ermutigenden Resultate gibt es noch immer Probleme. Sie bestehen vor allem in strukturellen Änderungen und im allmählichen Verlust des Elektrolyten und begrenzen Betriebsdauer und Zuverlässigkeit der Zellen. Günstige Schätzungen kommen für die Carbonat-Zelle auf ähnliche Produktionskosten wie für die Phosphorsäure-Zelle.

Die anderen Teil systeme eines Brennstoffzellen-Kraftwerks, die Anlage für die Brennstoff-Aufbereitung und der Wechselrichter, sind so weit entwickelt, daß sie zusammen mit der ersten Generation der Brennstoffzellen eingesetzt werden können. Die Brennstoff-Aufbereitungsanlagen können Erdgas und eine als Naphtha bezeichnete, zwischen 150 und 180 Grad Celsius siedende Fraktion des Erdöls zu einem wasserstoffreichen Gasgemisch verarbeiten. Gegenwärtig bemüht man sich, sie so weit zu entwickeln, daß sie auch mit höhersiedenden Erdölfraktionen und mit Produkten der Kohleverflüssigung betrieben werden können.

Die von den Brennstoffzellen gebotenen Vorteile werden sich erst nutzen lassen, wenn solche Zellen großtechnisch produziert werden. Hier liegt momentan das entscheidende Problem, denn die ersten Zellen werden verhältnismäßig teuer sein, und der Preis wird nur in dem Maß sinken, in dem die Produktion wächst (Bild 5). Nur wagemutige Unternehmer, finanzstarke Kunden und eine Energiepolitik, die einer Regierung die Möglichkeit gibt, beide zu unterstützen, werden zusammen in der Lage sein, eine Entwicklung einzuleiten und fortzusetzen, die im Interesse aller liegt, da sie es gestattet, Energie zu sparen und die Belastung der Umwelt zu vermindern.

In den USA gibt es zur Zeit drei Arbeitsprogramme, deren Absicht darin besteht, die Brennstoffzelle möglichst rasch so weit zu entwickeln, daß sie für die öffentliche elektrizitätsversorgung nützlich wird. Das erste Programm läuft unter dem Akronym TARGET (Team to Advance Research for Gas Energy Transformation). Es besteht seit 1967 und hat sich der mit Erdgas oder Synthesegas betriebenen Phosphorsäure-Zelle angenommen. Ziel der Arbeiten ist die Entwicklung kleiner Kraftwerke, die in großen Büro- oder Wohngebäuden installiert werden können. Da praktisch die gesamte Abfallwärme für Heiz- und Kühlzwecke von je 12,5 kilowatt Leistung ausprobiert. Aufgrund der so gewonnenen Erfahrungen baute man 1975 eine 40-Kilowatt-Anlage, die zwischen 1979 und 1981 in fünfzig Prototypen erprobt werden und 1982 in den Handel kommen soll. Für TARGET hat die Industrie bisher etwa hundert Millionen Dollar ausgegeben.

Das zweite Programm wurde 1972 von einigen Elektrizitätsversorgungsunternehmen unter der Bezeichnung FCG-1 (Fuel Cell Generator) ins Leben gerufen. Es beschäftigt sich mit Megawatt-Kraftwerken, die aus Phosphorsäure-Zellen bestehen. 1976 und 1977 zeigte eine Demonstrationsanlage mit einer Leistung von einem Megawatt, daß ein mit Naphtha betriebenes Brennstoffzellenkraftwerk geeignet ist, als lastabhängiger Elektrizitätserzeuger zu arbeiten, und den Ansprüchen der Industrie hinsichtlicht Wirkungsgrad und Umweltfreundlichkeit genügt. Bis 1980 will man mitten in New-York, an einer Stelle also, an der niemals ein herkömmliches Kraftwerk stehen könnte, ein 4,5-Megawatt-Brennstoffzellen-Kraftwerk errichten, dessen Kosten man auf sechzig Millionen Dollar schätzt. Ein drittes Programm, das zunächst allein von der Industrie getragen wurde, an dem sich jetzt aber auch das Energie-Ministerium beteiligt, widmet seine Aufmerksamkeit den Brennstoffzellen, die mit einer Carbonat-Schmelze als Elektrolyten arbeiten. Ein aus solchen Zellen bestehendes Kraftwerk, soll Kohle als primären Brennstoff verwenden können, seine Leistung wird einige hundert Megawatt betragen, und man rechnet mit einer Entwicklungszeit von etwa zehn Jahren.

Auch in der Bundesrepublik Deutschland wird an der Entwicklung von Brennstoffzellen gearbeitet, allerdings weniger mit dem Ziel, zu Kraftwerken

großer Leitung zu kommen. Notstromaggregate und Geräte für die elektrische Versorgung kleiner Einheiten (Gabelstapler, automatisierte Meßstationen) bis hinab zu Spannungsquellen, die in den menschlichen Körper implantiert werden können (beispielsweise für den Antrieb eines Herzschrittmachers) und mit Traubenzucker aus dem Blut als Brennstoff arbeiten, stehen hier im Vordergrund des Interesses.

Bild 1 : Dieser Stapel von nahezu fünfhundert Brennstoffzellen soll zusammen mit neunzehn anderen in einem 4,5-Megawatt-Brennstoffzellen-Kraftwerk in New York installiert werden. Jede Schicht des Stapels ist eine Brennstoff-Zelle, die eine Spannung von 0,64 Volt erzeugt und fünfhundert Watt leistet. Die Brennstoffzellen arbeiten mit Phosphorsäure als Elektrolyten und verwenden als Brennstoff ein wasserstoffreiches Gas, das aus einer als Naphtha bezeichneten, zwischen 150 und 180 Grad Celcius siedenden Erdölfraktion erzeugt wird. Als Oxidationsmittel dient der Sauerstoff der Luft. Das Schema einer solchen Zelle zeigt Bild 2.

Bild 2 : Schema einer Brennstoffzelle. Als Brennstoff dient ein aus Kohle oder Erdöl erzeugtes wasserstoffreiches Gas. An der Anode werden die Wasserstoff-Moleküle (H2) in positive geladene Elektronen Wasserstoff-Ionen (H+) und negativ geladene Elektronen (e) aufgespalten. Die Wasserstoff-Ionen werden im Elektrolyten zur Kathode transportiert. Die Elektronen fließen durch den äußeren Stromkreis von der Anode zur Kathode. Dort vereinigen sich Wasserstoff-Ionen und Elektronen mit dem als Oxidationsmittel dienenden Sauerstoff (O2) der Luft zu Wasser, das die Brennstoffzelle verläßt.

Bild 3 : Schema eines Brennstoffzellen-Kraftwerks. Steht zum Betrieb der Brennstoffzellen kein wasserstoffreiches Gasgemisch zur Verfügung, so kann das Kraftwerk auch mit Erdöl oder Kohle arbeiten, muß daraus aber in einem Brennstoff-Aufbereiter (oder Reformer) ein wasserstoff-reiches Gasgemisch erzeugen. Die Brennstoffzellen liefern eine Gleichspannung, die vom Wechselrichter in Wechselspannung umgewandelt werden muß, bevor sie an das öffentliche Elektrizitätsnetz abgegeben wird.

Bild 4 : Die meisten Maschinen, die Wärmeenergie in elektrische Energie umwandeln, nutzen die Wärmeenergie umso besser aus, je mehr sie in der Nähe ihrer vollen Nennleistung (der vom Hersteller angegebenen Maximalleistung) arbeiten. Dagegen unterliegt der Wirkungsgrad einer Brennstoffzelle zwischen 25 und 100 Prozent ihrer Nennleistung keiner sehr großen Änderung. Da von einem Kraftwerk nicht ständig die volle Leistung verlangt wird, braucht man Anlagen, die elektrische Energie in dem Maß erzeugen, in dem der Bedarf einen durchschnittlichen Wert über steigt. Hier erweisen sich Brennstoffzellen als günstig. Ihre Verwendung ermöglicht es anderen Maschinen, ständig bei voller Nennleistung zu arbeiten und so bei maximalen Wirkungsgrad den mittleren Bedarf zu decken.

Bild 5 : Die Kosten für den Bau eines Brennstoffzellen-Kraftwerks (farbige Kurve un farbige Zahlen) sind hier der Entwicklung der Kraftwerksgröße (schwarze Kurve und schwarze Zahlen) gegenübergestellt. Die ausgezogenen Kurven geben Erfahrungswerte, die gestrichelten Teile geschätzte Werte wieder. Die erste 1,5- Kilowatt-Anlage wurde in den späten sechziger Jahren für die US-Armee gebaut und kostete über hunderttausend Dollar. 1980 sollten die Kosten nur noch bei 350 Dollar pro Kilowatt liegen, sofern Brennstoffzellen bis dahin großtechnisch, das heißt im Umfang von fünfhundert Megawatt pro Jahr produziert werden können. Das wiederum setzt voraus, daß der markt für Brennstoffzellen bis dahin so groß geworden ist, daß er die gesamte Produktion aufnehmen kann.

Le texte a été saisi directement sur une console du C.I.R.C.E. et subi un codage destiné à conserver les richesses typologiques que ne permettaient pas de traiter les installations de l'époque.

La majuscule est codée par le '$', le Umlaut par une '*', le passage à la ligne par '_$_', les titres entre '‖', les sous- titres entre '|', le 'ß' est écrit 'S*'.

Sur la page suivante, nous montrons les premières phrases du texte allemand dans les fichiers créés par le module de mise en forme.

.TEXALL(TEXALL1) : C'est le fichier contenant le texte allemand d'origine.

.TEXALL1.SORTIEØ.CHAINES(CHAINE1) : Les phrases sont concaténées en chaînes de caractères, le langage de programmation PL/1 acceptant de traiter des chaînes de 32767 caractères.

.TEXALL1.SORTIE1.BASE : La phrase est découpée.

.TEXALL1.SORTIE2.BASE1 : On a inclus dans le fichier précédent les résulats de l'analyse du verbe.

.TEXALL1.SORTIE2.BASE21 : On ne conserve dans cette version que les mots composés potentiels.

.TEXALL1.SORTIE2.BASE23 : Les données précédentes sont tassées et disposées de façon à accélérer le traitement ultérieur.

.TEXALL(TEXALL1) :

```
00010  :: $BRENNSTOFFZELLENKRAFTWERKE :: . $ $IM NA*CHSTEN $JAHRZEHNT WIRD MAN VON EINEM $ELEKTRIZITA*TSWERK FORDERN . %
00020 DAS* ES EINEN HOHEN $WIRKUNGSGRAD HAT , MO*GLICHST WENIG $SCHMUTZ EMITTIERT . KEINEN $LA*RM VERURSACHT UND RASC%
00030 CH ZU INSTALLIEREN IST . $EIN VIEL VERSPRECHENDER $KANDIDAT IST DIE $BRENNSTOFFZELLE . $ $EINE $BRENNSTOFFZELLE %
00040 WANDELT DIE CHEMISCHE $ENERGIE EINES $BRENNSTOFFS DIREKT , DAS HEIS*T OHNE DEN $UMWEG U*BER DIE $WA*RME . IN %
00050 ELEKTRIZITA*T UM . $SCHON 1839 ERFAND $SIR $WILLIAM $GROVE . EIN ENGLISCHER $JURIST . DAS $GERA*T , ABER ES DAUZ
00060 ERTE LANGE , EHE ES ZU SEINEM $RECHT KAM . $BRENNSTOFFZELLEN VERSORGTEN DIE $GEMINI- UND $APOLLO-$RAUMSCHIFFE %
00070 MIT $ENERGIE UND FANDEN DAMIT EINE EBENSO EXOTISCHE WIE TEURE $ANWENDUNG . $HEUTE GIBT ES $BRENNSTOFFZELLEN IN %
00080 VERBESSERTEN UND TAUSENDMAL GRO*S*EREN $VERSIONEN . UND ES SCHEINT . ALS SEI DAS $STADIUM ERREICHT , IN DEM MA%
00090 N VON IHNEN EINEN NENNENSWERTEN $BEITRAG ZUR O*FFENTLICHEN $ELEKTRIZITA*TSVERSORGUNG ERWARTEN KANN . $ $EINE $BZ%
00100 RENNSTOFFZELLE ( $BILD 2 ) BESTEHT AUS ZWEI $ELEKTRODEN - EINER POSITIVEN ( DER $KATHODE ) UND EINER NEGATIVEN%
00110  ( DER $ANODE ) - , DIE DURCH EINEN $ELEKTROLYTEN GETRENNT SIND . $IM $ELEKTROLYTEN KO*NNEN $IONEN ( POSITIV ODZ
00120 ER NEGATIV GELADENE $ATOME . $MOLEKU*LE ODER $MOLEKU*LTEILE ) TRANSPORTIERT WERDEN . NICHT ABER DIE NEGATIV GEZ
00130 LADENEN $ELEKTRONEN . DIE FU*R DEN $ELEKTRIZITA*TSTRANSPORT IN METALLISCHEN $LEITERN VERANTWORTLICH SIND . $DER%
00140  $BRENNSTOFF ( BEISPIELSWEISE $WASSERSTOFF ) WIRD DER $ANODE ZUGEFU*HRT , WA*HREND MAN DIE $KATHODE MIT DEM $OZ
00150 XIDATIONSMITTEL ( BEISPIELSWEISE $SAUERSTOFF AUS DER $LUFT ) VERSORGT . $AN DER $ANODE REAKTANT EIN $KATALYSATOR%
00160  DIE $AUFSPALTUNG DES $WASSERSTOFF-$MOLEKU*LE!
```

.TEXALL1.SORTIE0.CHAINES(CHAINE1) :

```
1
:: $BRENNSTOFFZELLENKRAFTWERKE :: . $ $IM NA*CHSTEN $JAHRZEHNT WIRD MAN VON EINEM $ELEKTRIZITA*TSWERK FORDERN , DAS* ES EINEN HOHEN
$WIRKUNGSGRAD HAT , MO*GLICHST WENIG $SCHMUTZ EMITTIERT . KEINEN $LA*RM VERURSACHT UND RASCH ZU INSTALLIEREN IST . $EIN VIEL VERSPRE
CHENDER $KANDIDAT IST DIE $BRENNSTOFFZELLE . $ $EINE $BRENNSTOFFZELLE WANDELT DIE CHEMISCHE $ENERGIE EINES $BRENNSTOFFS DIREKT , DAS
 HEIS*T OHNE DEN $UMWEG U*BER DIE $WA*RME . IN $ELEKTRIZITA*T UM . $SCHON 1839 ERFAND $SIR $WILLIAM $GROVE . EIN ENGLISCHER $JURIST
 . DAS $GERA*T , ABER ES DAUERTE LANGE , EHE ES ZU SEINEM $RECHT KAM . $BRENNSTOFFZELLEN VERSORGTEN DIE $GEMINI- UND $APOLLO-$RAUMSCH
IFFE MIT $ENERGIE UND FANDEN DAMIT EINE EBENSO EXOTISCHE WIE TEURE $ANWENDUNG . $HEUTE GIBT ES $BRENNSTOFFZELLEN IN VERBESSERTEN UND
 TAUSENDMAL GRO*S*EREN $VERSIONEN . UND ES SCHEINT , ALS SEI DAS $STADIUM ERREICHT , IN DEM MAN VON IHNEN EINEN NENNENSWERTEN $BEITR
AG ZUR O*FFENTLICHEN $ELEKTRIZITA*TSVERSORGUNG ERWARTEN KANN . $ $EINE $BRENNSTOFFZELLE ( $BILD 2 ) BESTEHT AUS ZWEI $ELEKTRODEN - E
INER POSITIVEN ( DER $KATHODE ) UND EINER NEGATIVEN ( DER $ANODE ) - , DIE DURCH EINEN $ELEKTROLYTEN GETRENNT SIND . $IM $ELEKTROLYT
EN KO*NNEN $IONEN ( POSITIV ODER NEGATIV GELADENE $ATOME , $MOLEKU*LE ODER $MOLEKU*LTEILE ) TRANSPORTIERT WERDEN . NICHT ABER DIE NE
GATIV GELADENEN $ELEKTRONEN , DIE FU*R DEN $ELEKTRIZITA*TSTRANSPORT IN METALLISCHEN $LEITERN VERANTWORTLICH SIND . $DER $BRENNSTOFF
( BEISPIELSWEISE $WASSERSTOFF ) WIRD DER $ANODE ZUGEFU*HRT , WA*HREND MAN DIE $KATHODE MIT DEM $OXIDATIONSMITTEL ( BEISPIELSWEISE $S
AUERSTOFF AUS DER $LUFT ) VERSORGT . $AN DER $ANODE REAKTANT EIN $KATALYSATOR DIE $AUFSPALTUNG DES $WASSERSTOFF-$MOLEKU*LE IN $WASSER
STOFF-$IONEN ( $H+ ) UND $ELEKTRONEN ( E ) . $DA $A!
```

.TEXALL1.SORTIE1.BASE :

```
*0025
0206
0030
0000
0000
0003 006 013 020
0000
0000
0000
00025007020001 $MAN
00025007030002 BAUT
00025007040003 $BRENNSTOFFZELLEN
00025007050004 DAHER
00025007060005 SO
00025007070006 ,
00025007080007 DAS*
00025007090008 MAN
00025007100009 DEN
00025007110010 $ELEKTROLYTEN
00025007120011 ALS
00025007130012 DU=NNE
00025007140013 ,
00025007150014 FLACHE
00025007160015 $SCHICHT
00025007170016 ZWISCHEN
00025007180017 ZWEI
00025007190018 GLEICHFALLS
00025007200019 FLACHE
00025007210020 ,
00025007220021 PORO=S
00025007230022 GESTALTETE
00025007240023 UND
00025007250024 MIT
00025007260025 DEM
00025007270026 $KATALYSATOR
00025007280027 IMPRA=GNIERTE
00025007290028 $ELEKTRODEN
00025007300029 PACKT
00025007310030 .
```

Chaque phrase se présente ici sous une forme facilement exploitable. L'extrait ci-dessus concerne la phrase n°25. Son numéro est précédé d'une '*' à la première ligne.

Elle a 206 caractères (deuxième ligne) et 30 mots (troisième ligne). Les six lignes qui suivent indiquent le nombre et la position, dans l'ordre, des deux-points, points-virgules, virgules, parenthèses ouvrantes, parenthèses fermantes, tirets. Les 6ème, 13ème et 20ème mots sont bien des virgules. Les lignes suivantes commencent par une numérotation à 14 chiffres :

ØØØ25 numéro de phrase, ØØ7Ø2 numéro du mot dans le texte, ØØØ1 numéro du mot dans la phrase.

.TEXALL1.SORTIE2.BASE1 :

```
*0025
0206
0030
0000
0000
0003 006 013 020
0000
0000
0000
00025007020001 $MAN
00025007030002       BAUT                          BAU
00025007040003 $BRENNSTOFFZELLEN
00025007050004 DAHER
00025007060005 SO
00025007070006 ,
00025007080007 DAS*
00025007090008 MAN
00025007100009 DEN
00025007110010 $ELEKTROLYTEN
00025007120011 ALS
00025007130012 DU*NNE
00025007140013 ,
00025007150014 FLACHE
00025007160015 $SCHICHT
00025007170016 ZWISCHEN
00025007180017 ZWEI
00025007190018 GLEICHFALLS
00025007200019 FLACHE
00025007210020 ,
00025007220021 PORO*S
00025007230022       GESTALTETE                    GESTALT
00025007240023 UND
00025007250024 MIT
00025007260025 DEN
00025007270026 $KATALYSATOR
00025007280027       IMPRA*GNIERTE                 IMPRA*GNIERTE
00025007290028 $ELEKTRODEN
00025007300029       PACKT                         PACK
00025007310030 .
```

Tous les fichiers ...SORTIE2... sont des combinaisons du fichier ...SORTIE1.BASE et des résultats verbaux. La préparation du fichier de départ pour le module MOTS COMPOSES passe par .TEXALL1.SORTIE2.BASE1 dans lequel on inclut les verbes, .TEXALL1.SORTIE2.BASE21 dans lequel on supprime les verbes, les mots trop courts pour être composés (longueur inférieure à 6 caractères), les mots-outils de plus de 6 caractères. Il ne reste que des unités candidates à être des composés. Elles sont classées alphabétiquement dans .TEXALL1.SORTIE2.BASE22 et tassées de façon particulière dans .TEXALL1.SORTIE2.BASE23 :

N'y figurent, lorsqu'il y a plusieurs occurrences, que la première avec le mot et la dernière avec la numérotation seulement. Cela permet au module MOTS COMPOSES de fonctionner plus rapidement.

.TEXALL1.SORTIE2.BASE21

```
00024006860024 UNPRAKTISCHER
00024006870025 $ELEKTROLYT
00024006910029 $GEFA*S:*E
00024006950033 RAUMSPAREND
00024006970035 $BLO:*CKEN
00024006990037 $BRENNSTOFFZELLEN
00025007040003 $BRENNSTOFFZELLEN
00025007110010 $ELEKTROLYTEN
00025007160015 $SCHICHT
00025007190018 GLEICHFALLS
00025007270026 $KATALYSATOR
00025007290028 $ELEKTRODEN
00026007400009 U*BEREINANDERSTAPELN
00027007470002 $SPANNUNG
```

.TEXALL1.SORTIE2.BASE23

```
0000694 00028007920022 $WECHSELRICHTER
0000698 00124032200009
0000699 00029008460053 $WECHSELSPANNUNG
0000700 00124032220011
0000701 00005000730005 $WILLIAM
0000702 00002000200016 $WIRKUNGSGRAD
0000712 00136033740018
0000713 00061018460019 $WIRKUNGSGRADE
0000714 00063018990010
0000715 00058017530032 $WOHN-
0000716 00090025450015 $WOHNGEBA:UDEN
0000717 00145034230017 $ZAHLEN
0000718 00145034360030
0000719 00020005480010 $ZEITEINHEIT
0000720 00027007680023 $ZELLEN
0000729 00100027740004
0000730 00062018620005 $ZUKUNFT
0000731 00033009860011 $ZUVERLA*SSIGKEIT
0000732 00079022460018
0000733 00024006730011 $ZWECKE
0000734 00080022570008 A*HNLICHE
0000737 00015004340010 ALKALISCHEN
0000738 00079022380010 ALLNA*HLICHEN
0000739 00042012280018 ANDERENFALLS
0000775 00055016670005 BAUSTEINARTIG
0000778 00010002200004 BEISPIELSWEISE
0000781 00102028610030
0000783 00045013550029 BELIEBIG
0000803 00046013780019 BETRA:CHTLICHE
0000818 00029008080015 BILLIGEN
0000819 00035010260010 BRAUCHBAR


0001146 00147034550003 1,5-$KILOWATT-$ANLAGE
0001147 00098027210025 4,5-$MEGAWATT-$BRENNSTOFFZELLEN-$K
0001148 00103029020018
0001149 00093025930010 40-$KILOWATT-$ANLAGE
* LEXIQUE DE 00620 MOTS
* 00794 LIGNES AU TOTAL
END OF DATA
```

Pour le texte de néerlandais, nous aurons de la même façon :

.TEXOLL(TEXOLL1) :

```
00010  ¦ KERNENERGIE IN DE LAGE LANDEN . $J. $A. $GOEDKOOP . ¦ . ¦ INHOUD ¦ . $ # VOORWOORD # . $ 1. KERNREACTIES : 2
00020 10 . $ 2. DODEVAARD : 25 . $ 3. RADIOACTIVITEIT : 37 . $ 4. LANGS $HAAS EN $SCHELDE : 55 . $ 5. DE SPLIJTSTOFC2
00030 YCLUS : VAN URAANMIJN TOT ZOUTMIJN : 77 . $ 6. ALMELO EN $MOL : 94 . $ 7. ANDERE KERNREACTORTYPEN : 107 . $ 8.2
00040  KWEKEN AAN DE $RIJN : 126 . 9. KERNVERSMELTING : 139 . $ 10. KOEPELS EN EEN KASTEEL : 155 . $ # SLOTWOORD : #2
00050  164 . $ # LITERATUUR : # 167 . $ # REGISTER : # 171 . 0* KERNENERGIE IN DE LAGE LANDEN . $ SYMB. 1 KERNCENTRAL
00060 LE IN BEDRIJF . $ SYMB. 2 KERNCENTRALE IN AANBOUW . $ SYMB. 3 MINSTENS EKEN ANDERE KERNREACTOR . $ SYMB. 4 EN2
00070 KELE FABRIEKEN EN LABORATORIA 0* . ¦ VOORWOORD ¦ . $ VERHANDELINGEN OVER KERNENERGIE LIJKEN ER SOMS OP UIT DE 2
00080 LEZER TE INPONEREN . TOT VOOR ENKELE JAREN GEBEURDE DAT VOORAL DOOR HEM TE DOORDRINGEN VAN DE NIETIGHEID VAN 02
00090 E ATOOMKERNEN EN DE GROOTTE VAN DE DAARIN SLUITENDE KRACHTEN . DE BEHANDELING WAS DAN MEESTAL HISTORISCH , 02
00100 AARBIJ VAAK UITVOERIG AANDACHT WERD BESTEED AAN DE PRESTATIES VAN DE ONDERZOEKERS DIE HET BOUWWERK VAN DE MODE2
00110 RNE NATUURWETENSCHAP HEBBEN OPGERICHT EN DIE DAARVOOR VEELAL MET DE $NOBELPRIJS ZIJN BELOOND . $ SEDERTDIEN IS2
00120  DE WIND GEDRAAID . VOORAL IN DE PERS WORDEN NU IN EINDELOZE HERHALING UITSPRAKEN VAN DEZELFDE EN ANDERE $NOBEZ
00130 LPRIJSWINNAARS WEERGEGEVEN , WAARIN GEVAARSCHUUD WORDT TEGEN DE GEVAREN VAN DE TOEPASSING VAN DE KER!
```

.TEXOLL.SORTIE0.CHAINES(CHAINE1) :

```
 ¦ KERNENERGIE IN DE LAGE LANDEN . $J. $A. $GOEDKOOP . ¦ . ¦ INHOUD ¦ . $ # VOORWOORD # . $ 1. KERNREACTIES : 10 . $ 2. DODEWAARD :
25 . $ 3. RADIOACTIVITEIT : 37 . $ 4. LANGS $HAAS EN $SCHELDE : 55 . $ 5. DE SPLIJTSTOFCYCLUS : VAN URAANMIJN TOT ZOUTMIJN : 77 . $
6. ALMELO EN $MOL : 94 . $ 7. ANDERE KERNREACTORTYPEN : 107 . $ 8. KWEKEN AAN DE $RIJN : 126 . 9. KERNVERSMELTING : 139 . $ 10. KOEP
ELS EN EEN KASTEEL : 155 . $ # SLOTWOORD : # 164 . $ # LITERATUUR : # 167 . $ # REGISTER : # 171 . 0* KERNENERGIE IN DE LAGE LANDEN
 . $ SYMB. 1 KERNCENTRALE IN BEDRIJF . $ SYMB. 2 KERNCENTRALE IN AANBOUW . $ SYMB. 3 MINSTENS EKEN ANDERE KERNREACTOR . $ SYMB. 4 EN
KELE FABRIEKEN EN LABORATORIA 0* . ¦ VOORWOORD ¦ . $ VERHANDELINGEN OVER KERNENERGIE LIJKEN ER SOMS OP UIT DE LEZER TE IMPONEREN . T
OT VOOR ENKELE JAREN GEBEURDE DAT VOORAL DOOR HEM TE DOORDRINGEN VAN DE NIETIGHEID VAN DE ATOOMKERNEN EN DE GROOTTE VAN DE DAARIN SL
UITENDE KRACHTEN . DE BEHANDELING WAS DAN MEESTAL HISTORISCH , WAARBIJ VAAK UITVOERIG AANDACHT WERD BESTEED AAN DE PRESTATIES VAN
DE ONDERZOEKERS DIE HET BOUWWERK VAN DE MODERNE NATUURWETENSCHAP HEBBEN OPGERICHT EN DIE DAARVOOR VEELAL MET DE $NOBELPRIJS ZIJN BEL
OOND . $ SEDERTDIEN IS DE WIND GEDRAAID . VOORAL IN DE PERS WORDEN NU IN EINDELOZE HERHALING UITSPRAKEN VAN DEZELFDE EN ANDERE $NOBE
LPRIJSWINNAARS WEERGEGEVEN , WAARIN GEVAARSCHUUD WORDT TEGEN DE GEVAREN VAN DE TOEPASSING VAN DE KERNENE!
```

Le module de mise en forme découpera le texte en phrases :
.TEXOLL1.SORTIE1.BASE
y intégrera les résultats de l'analyse verbale
.TEXOLL1.SORTIE2.BASE21
et préparera le traitement des mots composés
.TEXOLL1.SORTIE2.BASE21 et **.TEXOLL1.SORTIE2.BASE23**

.TEXOLL1.SORTIE1.BASE :

```
:0029
0200
0030
0000
0000
0001 017
0000
0000
0000
00029002490001 VOORAL
00029002500002 IN
00029002510003 DE
00029002520004 PERS
00029002530005 WORDEN
00029002540006 NU
00029002550007 IN
00029002560008 EINDELOZE
00029002570009 HERHALING
00029002580010 UITSPRAKEN
00029002590011 VAN
00029002600012 DEZELFDE
00029002610013 EN
00029002620014 ANDERE
00029002630015 $NOBELPRIJSWINNAARS
00029002640016 WEERGEGEVEN
00029002650017 ,
00029002660018 WAARIN
00029002670019 GEWAARSCHUWD
00029002680020 WORDT
00029002690021 TEGEN
00029002700022 DE
00029002710023 GEVAREN
00029002720024 VAN
00029002730025 DE
00029002740026 TOEPASSING
00029002750027 VAN
00029002760028 DE
00029002770029 KERNENERGIE
00029002780030 .
```

.TEXOLL1.SORTIE2.BASE1 :

```
*0046
0199
0032
0000
0000
0001 016
0000
0000
0000
00046007160001 DE
00046007170002 TITEL
00046007180003 VAN
00046007190004 DIT
00046007200005 BOEKJE
00046007210006      ZOU
00046007220007 DE
00046007230008 VERWACHTING
00046007240009      KUNN EN                    KUNN
00046007250010      WEKK EN                    WEKK
00046007260011 DAT
00046007270012 OOK
00046007280013 BELEIDSASPECTEN
00046007290014      WORD EN                    WORD
00046007300015     BE SPROK EN                 BESPROK
00046007310016 ,
00046007320017 ZOALS
00046007330018 DE
00046007340019 MATE
00046007350020 WAARIN
00046007360021 KERNENERGIE
00046007370022      ZAL
00046007380023      WORD EN                    WORD
00046007390024    TOE GE PAS T                 TOEPAS
00046007400025 EN
00046007410026 DE
00046007420027 MANIER
00046007430028 WAAROP
00046007440029 DAT
00046007450030      WORD T                     WORD
00046007460031      GEORGANISEER D             ORGANISEER
00046007470032 .
```

.TEXOLL1.SORTIE2.BASE21 :

```
00045007020006 ONTWIKKELING
00045007050009 INTERESSANT
00045007130017 NOODZAKELIJKE
00046007230008 VERWACHTING
00046007280013 BELEIDSASPECTEN
00046007360021 KERNENERGIE
00047007500003 ASPECTEN
00047007510004 INCIDENTEEL
00047007650018 TECHNISCHE
00047007660019 INFORMATIE
```

.TEXOLL1.SORTIE2.BASE23 :

```
*...SORTIE2.BASE23
*00051
*04186
0000001 00057009620016 $ARDENNEN
0000002 00033004230036 $BELGIE*
0000005 00057009500004
0000006 00932003620027 $BELGISCHE
0000007 00049008240007 $CENTRUM
0000008 00035004800031 $DODEWAARD
0000010 00219049000009
0000011 00033004290042 $DUITSE
0000012 00067012120013 $GASUNIE
0000013 00002000110003 $GOEDKOOP
0000014 00063011030033 $GRONINGSE
0000015 00040005980031 $KALKAR
0000016 00033004210034 $NEDERLAND
0000022 00063010900020
0000023 00931003210014 $NEDERLANDSE
0000026 00219049060015
0000027 00027002380035 $NOBELPRIJS
0000028 00029002630015 $NOBELPRIJSWINNAARS
0000029 00049008230006 $REACTOR
0000030 00009000470006 $SCHELDE
```

```
0000952 00071013360022 ZUURSTOFATOmEN
0000953 00129025240019
0000954 00112022980024 ZUURSTOFATOOm
0000955 00115023880010
0000956 00213047730017 ZWAARDER
0000957 00175039040009 ZWAARSTE
0000958 00126027050022 0,7/100
0000959 00184041240017 10**-14
0000960 00126026990016 99,3/100
* LEXIQUE DE 00487 MOTS
* 00648 LIGNES AU TOTAL
END OF DATA
```

Pour les textes en luxembourgeois, le système est identique. Le fichier texte s'intitulera **.TEXLUX(TEXLUX1)**, la chaîne **.TEXLUX1.SORTIEØ.CHAINES(CHAINE1)**, avec les fichiers intermédiaires **.TEXLUX1.SORTIE1.BASE, .TEXLUX.SORTIE2.BASE1....**

```
Ø0010  ! $JEAN-$PAUL $SCHNEIDER ! . $ !! D' $REFORM VUN DER $LE*TZEBUERGER $EKONOMIE ( 1. $DEEL ) !! . $ ! 1. $ D' $STRUKZ
Ø0020 TUR VUN DER $LZ
Ø0030 E*TZEBUERGER $EKONOMIE ! . $ BIS AN D' $NE*TT VUN 19TEN $JOERHONDERT WAR $LE*TZEBUERG EN AARMT $LAND : E*T GOUF Z
Ø0040 DEEMOLS KENG GRE>ISSER $INDUSTRIE , DEN $DE>NGSCHLEESCHTUNGSSECTEUR WAR GANZ KLENG . ONGEFE>IER 60/100 VUN DE $LEIT Z
Ø0050 HUN AN DER $LANDWIRTSCHAFT GESCHAFFT , WOUVUN DE>I MEESCHT E KLENGT $AKOMMES HATEN , DAT KNAPPS DUERGONG FIR ZE LIZ
Ø0060 EUEN , 22/100 HUN AN DER $INDUSTRIE AN AM $HANDWIERK GESCHAFFT , 18/100 AM $HANDEL , DE FRA*IE $BERUFFER AN DE $SERVZ
Ø0070 ICERZ                .
Ø0080  . $ AM $JOER 1877 HUET DEN ENGLESCHEN $INGENIEUR $GILCHRIST $THOMAS ENG $METHOD ERFONNT , FIR AUS PHOSPHORRA*IZ
Ø0090 CHEN $EISENE>IERZ $QUALITE>ITSSTOL ZE KRE>IEN . DE*S $ERFINDUNG HUET E*T ME>IGLECH GEMAACH , LE*TZEBUERGESCHTZ
Ø0100  A LOTHRE>NGESCHT $EISENE>IERZ ZE VERSCHAFFEN , DAT VIRDRUN WE>INT DEN HE>IGE $PHOSPHORGEHALT NE*T GEBRAUCHTZ
Ø0110  KONNT GIN . AN DE $JORZE>NGTEN DONO HUET SECH ENG BEDA*ITEND $STOLINDUSTRIE BEI ONS ENTWE>CKELT , DE>I OCZ
Ø0120 H D' $GRE*NNUNG VUN ANEREN $INDUSTRIEN E*NNERSTE*TZT HUET . AN ENGEMS HUET DEN $AUSBAU VUM $EISENBUNN-Z
Ø0130 $NETZ E SE>CHEREN $TRANSPORTWEE GESCHAF AN ESOU ENG VUN DE WICHTEGSTE $VIRAUSSETZONGEN ERFE*LLT , FIR D' $BLE>Z
Ø0140 I VUN EISER $EKONOMIE . EN $NIEWEPRODUKT VUN DER $STOLPRODUKTIOUN , D' $THOMASMIEL , HUET EISER $LANDZ
Ø0150 WIRTSCHAFT GEHOLLEF , FIR ME>I ZE PRODUZE>IEREN . $ D' $LANDWIRTSCHAFT HUET , MODEEM SI RATIONALISE>IERT A MODZ
Ø0160 ERNISE>IERT WAR , HIR $PRODUKTIVITE>IT GANZ SCHE>IN AN D' $LUT GEDRIWWEN : VUN 1870 BIS 1907 AS D' $ZUEL VUN DZ
Ø0170 E $LEIT , DE>I AN DER $LANDWIRTSCHAFT ( D.H. AM $PRIMA*RE-$SECTEUR ) GESCHAFFT HUN , VUN !
```

.TEXLUX(TEXLUX1) :

! $JEAN-$PAUL $SCHNEIDER ! . $!! D' $REFORM VUN DER $LE*TZEBUERGER $EKONOMIE (1. $DEEL) !! . $! 1. $ D' $STRUKTUR VUN DER $LE*T ZEBUERGER $EKONOMIE ! . $ BIS AN D' $NE*TT VUN 19TEN $JOERHONDERT WAR $LE*TZEBUERG EN AARMT $LAND : E*T GOUF DEEMOLS KENG GRE>ISSER $INDUSTRIE , DEN $DE>NGSCHLEESCHTUNGSSECTEUR WAR GANZ KLENG . ONGEFE>IER 60/100 VUN DE $LEIT HUN AN DER $LANDWIRTSCHAFT GESCHAFFT , WOUVUN DE>I MEESCHT E KLENGT $AKOMMES HATEN , DAT KNAPPS DUERGONG FIR ZE LIEUEN , 22/100 HUN AN DER $INDUSTRIE AN AM $HANDWIERK GESC HAFFT , 18/100 AM $HANDEL , DE FRA*IE $BERUFFER AN DE $SERVICER . $ AM $JOER 1877 HUET DEN ENGLESCHEN $INGENIEUR $GILCHRIST $THOMAS ENG $METHOD ERFONNT , FIR AUS PHOSPHORRA*ICHEN $EISENE>IERZ $QUALITE>ITSSTOL ZE KRE>IEN . DE*S $ERFINDUNG HUET E*T ME>IGLECH GEMAACH , LE*TZEBUERGESCHT A LOTHRE>NGESCHT $EISENE>IERZ ZE VERSCHAFFEN , DAT VIRDRUN WE>INT DEN HE>IGE $PHOSPHORGEHALT NE*T GEBRAUCHT KONN T GIN . AN DE $JORZE>NGTEN DONO HUET SECH ENG BEDA*ITEND $STOLINDUSTRIE BEI ONS ENTWE>CKELT , DE>I OCH D' $GRE*NNUNG VUN ANEREN $IND USTRIEN E*NNERSTE*TZT HUET . AN ENGEMS HUET DEN $AUSBAU VUM $EISENBUNN-$NETZ E SE>CHEREN $TRANSPORTWEE GESCHAF AN ESOU ENG VUN DE WI CHTEGSTE $VIRAUSSETZONGEN ERFE*LLT , FIR D' $BLE>I VUN EISER $EKONOMIE . EN $NIEWEPRODUKT VUN DER $STOLPRODUKTIOUN , D' $THOMASMIEL , HUET EISER $LANDWIRTSCHAFT GEHOLLEF , FIR ME>I ZE PRODUZE>IEREN . $ D' $LANDWIRTSCHAFT HUET , MODEEM SI RATIONALISE>IERT A MODERNI SE>IERT WAR , HIR $PRODUKTIVITE>IT GANZ SCHE>IN AN D' $LUT GEDRIWWEN : VUN 1870 BIS 1907 AS D' $ZUEL VUN DE $LEIT , DE>I AN DER $LAN DWIRTSCHAFT (D.H. AM $PRIMA*RE-$SECTEUR) GESCHAFFT HUN , VUN 60/100 OP 43,2/100 GEFALL , GE>INT 38,4/100 AN DER $INDUSTRIE ($SEKU NDA*RE-$SECTEUR) AN 18,4/100 AN DEN SERVICER ($TERTIA*RE-$SECTEUR) AM $JOER 1907 . $ DE*S ENTWE>CKLUNG AS AM 20TEN $JOERHONNERT U EIDERGANG AN AS CHARAKTERISTESCH FIR A

.TEXLUX1.SORTIEØ.CHAINES(CHAINE1) :

```
*0006
0155
0022
0000
0000
0001 014
0000
0000
0000
00006001070001 $
00006001080002 AM
00006001090003 $JOER
00006001100004 1877
00006001110005 HUET
00006001120006 DEN
00006001130007 ENGLESCHEN
00006001140008 $INGENIEUR
00006001150009 $GILCHRIST
00006001160010 $THOMAS
00006001170011 ENG
00006001180012 $METHOD
00006001190013 ERFONNT
00006001200014 ,
00006001210015 FIR
00006001220016 AUS
00006001230017 PHOSPHORRA*ICHEN
00006001240018 $EISENE>IERZ
00006001250019 $QUALITE>ITSSTOL
00006001260020 ZE
00006001270021 KRE>IEN
00006001280022 .
```

.TEXLUX1.SORTIE1.BASE :

```
*0006
0155
0022
0000
0000
0001 014
0000
0000
0000
00006001070001 $
00006001080002 AM
00006001090003 $JOER
00006001100004 1877
00006001110005      HUE T                          HUE
00006001120006 DEN
00006001130007 ENGLESCHEN
00006001140008 $INGENIEUR
00006001150009 $GILCHRIST
00006001160010 $THOMAS
00006001170011 ENG
00006001180012 $METHOD
00006001190013     ER FONN T                       ERFONN
00006001200014 ,
00006001210015 FIR
00006001220016 AUS
00006001230017 PHOSPHORRA*ICHEN
00006001240018 $EISENE>IERZ
00006001250019 $QUALITE>ITSSTOL
00006001260020 ZE
00006001270021      KRE>IE N                       KRE>IE
00006001280022 .
```

.TEXLUX1.SORTIE2.BASE1 :

Pour un texte anglais :

.TEXANG(TEXANG1) :

```
:: $FUEL-$CELL $POWER $PLANTS :: . $ $OVER THE NEXT DECADE ELECTRIC UTILITIES IN THE $U.$S. WILL REQUIRE POWER %
ILL CERTAIN UNUSUAL REQUIREMENTS : HIGH EFFICIENCY , LOW EMISSION OF POLLUTANTS , QUIET OPERA%
RATORS MUST BE ABLE TO SUPPLY ELECTRICITY IN URBAN AREAS WHERE CONVENTIONAL GENERATORS WOULD BE UNACCEPTABLE FOR ENVIRONMENTAL REASO
NS . $A LIKELY CANDIDATE IS THE FUEL CELL . $ $A FUEL CELL CONVERTS THE CHEMICAL ENERGY OF A FUEL INTO ELECTRICITY DIRECTLY , WITH N
O INTERMEDIATE COMBUSTION CYCLE . $FOR A DEVICE THAT WAS INVENTED IN 1839 ( BY $SIR $WILLIAM $GROVE , A $BRITISH JURIST WHO MADE NOT
EWORTHY CONTRIBUTIONS TO SCIENCE ) THE FUEL CELL HAS TAKEN A LONG TIME TO COME INTO ITS OWN . $IT DID FURNISH POWER FOR THE $GEMINI
AND $APOLLO SPACECRAFT , BUT THAT WAS AN EXOTIC AND EXPENSIVE APPLICATION . $NOW THE FUEL CELL , VASTLY IMPROVED OVER THE SPACECRAFT
   VERSIONS AND IN ASSEMBLIES 1,$$$ TIMES LARGER THAN THE ONES CARRIED BY THE SPACECRAFT , APPEARS TO HAVE REACHED A STAGE WHERE IT CA
N MAKE A SIGNIFICANT CONTRIBUTION TO A NATION'S SUPPLY OF ELECTRICITY . $INDEED , IT IS VIEWED BY THE ELECTRIC-UTILITY INDUSTRY IN T
HE $U.$S. AS AN IMPORTANT ALTERNATIVE FOR MEETING THE LOAD GROWTH EXPECTED OVER THE NEXT TWO DECADES AND FOR DOING SO IN A WAY THAT
IS ENVIRONMENTALLY ACCEPTABLE AND CONSERVES FUEL . $ $IN THE SHORT RUN THE HOPE IS THAT FUEL-CELL SYSTEMS CAN BE DEPLOYED IN THE 198
0'S FOR HANDLING PEAK LOADS AND FOR WHAT THE UTILITY INDUSTRY CALLS LOAD FOLLOWING . $PEAKING GENERATORS ARE STARTED ONLY WHEN THE N
EED FOR ADDITIONAL POWER IS TEMPORARILY HIGH . $LOAD-FOLLOWING GENERATORS ARE STARTED DAILY AND RUN MOST OF THE TIME TO COPE WITH DA
ILY SWINGS IN THE LOAD ; THEY MAY BE SHUT !
```

.TEXANG1.SORTIE0.CHAINES(CHAINE1) :

```
$$$$10  :: $FUEL-$CELL $POWER $PLANTS :: . $ $OVER THE NEXT DECADE ELECTRIC UTILITIES IN THE $U.$S. WILL REQUIRE POWER %
$$$$20 GENERATORS THAT FULFILL CERTAIN UNUSUAL REQUIREMENTS : HIGH EFFICIENCY , LOW EMISSION OF POLLUTANTS , QUIET OPERA%
$$$$30 ATION AND QUICK INSTALLATION . $THE GENERATORS MUST BE ABLE TO SUPPLY ELECTRICITY IN URBAN AREAS WHERE CONVENTIO%
$$$$40 NAL GENERATORS WOULD BE UNACCEPTABLE FOR ENVIRONMENTAL REASONS . $A LIKELY CANDIDATE IS THE FUEL CELL . $ $A FUEL
$$$$50 L CELL CONVERTS THE CHEMICAL ENERGY OF A FUEL INTO ELECTRICITY DIRECTLY , WITH NO INTERMEDIATE COMBUSTION CYCLE %
$$$$60 . $FOR A DEVICE THAT WAS INVENTED IN 1839 ( BY $SIR $WILLIAM $GROVE , A $BRITISH JURIST WHO MADE NOTEWORTHY CONTR
$$$$70 RIBUTIONS TO SCIENCE ) THE FUEL CELL HAS TAKEN A LONG TIME TO COME INTO ITS OWN . $IT DID FURNISH POWER FOR THE %
$$$$80 $GEMINI AND $APOLLO SPACECRAFT , BUT THAT WAS AN EXOTIC AND EXPENSIVE APPLICATION . $NOW THE FUEL CELL , VASTLY %
$$$$90 IMPROVED OVER THE SPACECRAFT VERSIONS AND IN ASSEMBLIES 1,$$$ TIMES LARGER THAN THE ONES CARRIED BY THE SPACECRAF
$$110 FT , APPEARS TO HAVE REACHED A STAGE WHERE IT CAN MAKE A SIGNIFICANT CONTRIBUTION TO A NATION'S SUPPLY OF ELECTRI
$$120 ICITY . $INDEED , IT IS VIEWED BY THE ELECTRIC-UTILITY INDUSTRY IN THE $U.$S. AS AN IMPORTANT ALTERNATIVE FOR MEE
$$130 ETING THE LOAD GROWTH EXPECTED OVER THE NEXT TWO DECADES AND FOR DOING SO IN A WAY THAT IS ENVIRONMENTALLY ACCEP%
$$140 TABLE AND CONSERVES FUEL . $ $IN THE SHORT RUN THE HOPE IS THAT FUEL-CELL SYSTEMS CAN BE DEPLOYED IN THE 1980'S %
$$150 FOR HANDLING PEAK LOADS AND FOR WHAT THE UTILITY INDUSTRY CALLS LOAD FOLLOWING . $PEAKING GENERATORS ARE STARTED %
$$160 ONLY WHEN THE NEED FOR ADDITIONAL POWER IS TEMPORARILY HIGH . $LOAD-FOLLOWING GENERATORS ARE STARTED DAILY AND RU
$$170 UN MOST OF THE TIME TO COPE WIT!
```

.TEXANG1.SORTIE1.BASE :

```
*0002
0218
0034
0000
0001 020
0002 023 028
0000
0000
0000
00002000080001 $
00002000090002 $OVER
00002000100003 THE
00002000110004 NEXT
00002000120005 DECADE
00002000130006 ELECTRIC
00002000140007 UTILITIES
00002000150008 IN
00002000160009 THE
00002000170010 $U.$S.
00002000180011 WILL
00002000190012 REQUIRE
00002000200013 POWER
00002000210014 GENERATORS
00002000220015 THAT
00002000230016 FULFILL
00002000240017 CERTAIN
00002000250018 UNUSUAL
00002000260019 REQUIREMENTS
00002000270020 :
00002000280021 HIGH
00002000290022 EFFICIENCY
00002000300023 ,
00002000310024 LOW
00002000320025 EMISSION
00002000330026 OF
00002000340027 POLLUTANTS
00002000350028 ,
00002000360029 QUIET
00002000370030 OPERATION
00002000380031 AND
00002000390032 QUICK
00002000400033 INSTALLATION
00002000410034 .
```

Pour un texte en français :

.TEXTFRA(TEXTFRA1) :

```
00020 ARD . EN TANT QUE DISCIPLINE MATHE<MATIQUE , ELLE NE PEUT SE DE<VELOPPER D'UNE MANIE>RE RIGOUREUSE QUE SI ELLE%
00030  SE FONDE SUR UN SYSTE>ME DE DE<FINITIONS ET D ' AXIOMES BIEN EXPLICITES . HISTORIQUEMENT LA FORMULATION D'UNE%
00040  TELLE BASE AXIOMATIQUE ET L'E<LABORATION MATHE<MATIQUE DE LA $THE<ORIE REMONTENT AUX ANNE<ES 1930 . CE N'EST %
00050 EN EFFET QU'A> CETTE E<POQUE QUE LA THE<ORIE DE LA MESURE ET DE L'$INTE<GRATION S'EST TROUVE<E SUFFISAMMENT DE%
00060 <VELOPPE< SUR DES ESPACES GE<NE<RAUX POUR FOURNIR A> LA $THE<ORIE DES $PROBABILITE<S SES DE<FINITIONS FONDAME%
00070 NTALES EN ME*ME TEMPS QUE SON PLUS PUISSANT OUTIL DE DE<VELOPPEMENT . $ DEPUIS LORS , LES NOMBREUSES RECHERCHE%
00080 S ENTREPRISES DANS LE DOMAINE THE<ORIQUE COMME DANS LE DOMAINE CONCRET , EN PARTICULIER CELLES UTILISANT LES E%
00090 SPACES FONCTIONNELS , N'ONT FAIT QUE CONFIRMER LES LIENS E<TROITS E<TABLIS ENTRE LA $THE<ORIE DES $PROBABILITE%
00100 <S ET LA $THE<ORIE DE LA $MESURE . CES LIENS SONT D'AILLEURS TELLEMENT E<TROITS QUE CERTAINS AUTEURS N' ONT VU%
00110 ULU VOIR DANS LA $THE<ORIE DES $PROBABILITE<S QU'UN PROLONGEMENT ( AUSSI IMPORTANT FUT-IL ! ) DE LA $THE<ORIE %
00120 DE LA $MESURE . $ EN TOUT CAS , IL EST ACTUELLEMENT IMPOSSIBLE DE POURSUIVRE DES E<TUDES APPROFONDIES DE $THE<%
00130 ORIE DES $PROBABILITE<S ET DE $STATISTIQUE MATHE<MATIQUE SANS UTILISER CONSTAMMENT LA $THE<ORIE DE LA $MESURE %
00140 . A> NOINS DE SE LIMITER A> L'E<TUDE DE MODE>LES PROBABILISTES TRE>S E<LE<MENTAIRES ET DE S'INTERDIRE EN PARTI%
00150 CULIER DE CONSIDE<RER DES FONCTIONS ALE<ATOIRES . ON ESSAIE PARFOIS , IL EST VRAI , DE TRAITER LES PROBLE>MES %
00160 DE CONVERGENCE DU $CALCUL DES $PROBABILITE<S DANS LE CADRE LIMITE< DE L'E<TUDE DES FONCTIONS DE RE<PARTITION :%
00170  CETTE MANIE>RE DE PROCE<DER NE FOURNIT QU'UNE FAUSSE SIMPLIFICATION DE LA QUESTION ET DISSIMULE DE PLUS LES %
00180 ASES INTUITIVES DE CES PROBLE>MES . $ CE LIVRE REPRODUIT L'E
```

Cette série de modifications, qui part du texte et aboutit à .SORTIE2.BASE23 pour l'étude des mots composés, inclut en cours de route les résultats de .PROLOG et de .VERBAL.

4.3.2 L'analyse lexicale et morphologique

4.3.2.1 Les mots outils et la partie numérale (.PROLOG)

Après .LECTEXT et .DECPHR, .PROLOG code l'ensemble des mots-outils, simples ou disjoints, rangés dans deux listes ouvertes. (.FIXALL(OUTALL) et .FIXALL(EXPRALL) ainsi que la partie numérale.

4.3.2.1.1 Les mots outils atomiques (.FIXALL(OUTALL))

Ce fichier partitionné contient 842 enregistrements, composés d'un mot-outil simple (atomique) associé à un code de trois caractères.
La classification, propre au système, n'est que provisoire. Elle devrait évoluer au fil des versions et lors de l'élaboration du logiciel de transfert, dans le sens d'une simplification. Les ambiguïtés sont assez nombreuses mais dépassent rarement le nombre de 3 (d'où la taille du code utilisé).

Les unités qui sortent de ce cadre sont traitées à part (*ZU...).

Code (pour les deux listes) suivi d'un exemple:

A adverbe **ebenfalls**
B adverbe pronominal **daneben**
C partie numérale **dritte** (cf. 4.3.5.3)
D adverbe interrogatif **wo**
E adverbe relatif **wobei**
F locution adverbiale **ab und zu**
G préposition + déterminatif **im**
H adjectif invariable **anderthalb**
I article défini **der**
J article indéfini **ein**
K pronom relatif **der**
L outil de la comparaison **wie**
M conjonction de coordination **und**
N conjonction de subordination **daß**
O particule séparable **auf**
P préposition **auf**
Q posposition **zuliebe**
R pré/postposition **gegenüber**
S indéfini **wenig**
T interrogatif **was**
U possessif **sein**
V démonstratif **dieser**
W réfléchi **sich**
X pronom invariable **seinesgleichen**
Y pronom personnel **er**
Z adjectif **lustig**

La distinction entre adverbe (A), adverbe pronominal (B) et locution adverbiale (F) n'est pas exploitée au cours de l'analyse syntaxique, telle que nous l'avons construite. De même, pourrait-on réduire les formes contractées préposition-déterminatif ou articles définis-articles indéfinis à une classe sans que le système en souffre.

C'est le fonctionnement du mot-outil qui importe. Cela signifie, par exemple, que la classe des postpositions ne pourra jamais se substituer à la classe des prépositions.

Nous avons maintenu ces classes artificielles, à l'issue d'un cheminement sinueux, au long duquel la recherche pragmatique a souvent bousculé la théorie linguistique.

Dans cet ordre d'idées, nous avons constaté à maintes reprises que le traitement automatique de longs textes (80 000 mots minimum) ne s'accommodait pas des modèles élaborés par telle ou telle école. Les méthodes de l'analyse classique que nous ont enseignées nos professeurs de latin ou de grec ne sont pas très différentes, parfois, d'algorithmes présentés.

.FIXALL(OUTALL) :

```
00010 .FIXALL(OUTALL)
00020 00042
00030 00052
00040 06348
00050 APO AB
00060 A00 ABENDS
00070 MA0 ABER
00080 A00 ABERMALS
00090 APO ABSEITS
00100 A00 ABWA*RTS
```

```
00110 P00 ABZU*GLICH
00120 DS0 ALL
00130 DS0 ALLE
00140 A00 ALLEDEM
00150 DS0 ALLEM
00160 A00 ALLEMAL
00170 DS0 ALLEN
00180 A00 ALLENFALLS
00190 A00 ALLENTHALBEN
00200 DS0 ALLER
00210 A00 ALLERART
00220 A00 ALLERDINGS
00230 H00 ALLERHAND
00240 H00 ALLERLEI
00250 A00 ALLERSEITS
00260 A00 ALLERWA*RTS
00270 DS0 ALLES
00280 A00 ALLESAMT
00290 A00 ALLEWEGE
00300 A00 ALLEWEIL
00310 A00 ALLEZEIT
00320 HAM ALLEIN
00330 DS0 ALLE
00340 A00 ALLHIER
00350 A00 ALLSEITS
00360 A00 ALLU*BERALL
00370 A00 ALLZU
00380 A00 ALLZUMAL
00390 A00 ALLZUSEHR
00400 A00 ALLZUVIEL
00410 *01 ALS
00420 A00 ALSBALD
00430 A00 ALSDANN
00440 AM0 ALSO
00450 GL0 AM
00460 PAO AN
00470 A00 ANBEI
00480 S00 ANDEREM
00490 S00 ANDEREN
00500 S00 ANDERER
00510 S00 ANDERES
00520 S00 ANDERE
00530 A00 ANDERNFALLS
00540 A00 ANDERNORTS
00550 A00 ANDERNTAGS
00560 A00 ANDERS
00570 A00 ANDERERSEITS
00580 A00 ANDRERSEITS
00590 A00 ANDERSRUM
00600 A00 ANDERSWO
00610 A00 ANDERSWOHER
00620 A00 ANDERSWOHIN
00630 H00 ANDERTHALB
00640 A00 ANEINANDER
00650 AP0 ANFANGS
00660 P00 ANGESICHTS
00670 P00 ANHAND
00680 P00 ANLA*S*LICH
00690 G00 ANS
00700 P00 ANSTATT
00710 P00 ANSTELLE
00720 A00 AUCH
00730 PAO AUF
00740 A00 AUFEINANDER
00750 P00 AUFGRUND
00760 G00 AUFS
00770 A00 AUS*EN
00780 P00 AUS*ER
00790 A00 AUS*ERDEM
00800 AP0 AUS*ERHALB
00810 A00 AUS*ERSTANDE
00820 APO AUS
00830 A00 AUSEINANDER
00840 A00 AUSNAHMSWEISE
00850 A00 BALD
00860 A00 BALDIGST
00870 A00 BALDMO*GLICHST
00880 A00 BAS*
00890 A00 BEDINGUNGSWEISE
00900 PAO BEI
00910 DS0 BEIDE
00920 A00 BEIDEMAL
00930 H00 BEIDERLEI
00940 A00 BEIDERSEITS
00950 DS0 BEIDES
00960 A00 BEIEINANDER
00970 G00 BEIM
00980 A00 BEINAHE
00990 A00 BEISAMMEN
01000 A00 BEISEITE
01010 A00 BEISPIELSWEISE
01020 A00 BEREITS
01030 A00 BESONDERS
01040 A00 BESTENFALLS
01050 A00 BESTENS
01060 P00 BETREFFS
01070 N00 BEVOR
01080 CP0 BEZU*GLICH
01090 P00 BINNEN
01100 PN0 BIS
01110 A00 BISHER
01120 AN0 DA
01130 B00 DABEI
01140 D00 DADURCH
01150 B00 DAFU*R
01160 B00 DAGEGEN
01170 A00 DAHEIM
01180 A00 DAHER
01190 A00 DAHIN
01200 A00 DAHINAB
01210 A00 DAHINAUF
01220 A00 DAHINEIN
01230 A00 DAHINTEN
01240 B00 DAHINTER
01250 A00 DAHINU*BER
01260 A00 DAHINUNTER
01270 A00 DAMALS
01280 BN0 DAMIT
01290 B00 DANACH
01300 B00 DANEBEN
01310 A00 DANIEDER
01320 P00 DANK
01330 P00 DANN
01340 000 DAR
01350 B00 DARAN
01360 B00 DARAUF
01370 A00 DARAUFHIN
01380 B00 DARAUS
01390 A00 DAREIN
01400 B00 DARIN
01410 B00 DARU*BER
01420 B00 DARUM
01430 B00 DARUNTER
01440 IVK DAS
01450 AJ0 DASELBST
01460 V00 DASJENIGE
01470 V00 DASSELBE
01480 N00 DAS*
01490 B00 DAVON
01500 B00 DAVOR
01510 B00 DAWIDER
01520 B00 DAZU
01530 B00 DAZWISCHEN
01540 D00 DEIN
01550 U00 DEINE
01560 U00 DEINEM
01570 U00 DEINEN
01580 UY0 DEINER
01590 U00 DEINES
01600 X00 DEINESGLEICHEN
01610 IVK DEM
01620 A00 DEMENTGEGEN
01630 A00 DEMGEGENU*BER
01640 A00 DEMGEMA*S
01650 A00 DEMNACH
01660 A00 DEMNA*CHST
01670 V00 DENSELBEN
01680 A00 DEMZUFOLGE
01690 IVK DEN
01700 VK0 DENEN
01710 hA0 DENN
01720 A00 DENNOCH
01730 V00 DENSELBEN
01740 IVK DER
01750 A00 DERART
01760 VK0 DEREN
01770 VK0 DERER
01780 D00 DERGLEICHEN
01790 A00 DEREINST
01800 V00 DERJENIGE
01810 A00 DERMAS*EN
01820 V00 DERSELBE
01830 V00 DERSELBEN
01840 A00 DERWEIL
01850 A00 DERZEIT
01860 I00 DES
01870 A00 DESFALLS
01880 AD0 DESGLEICHEN
01890 A00 DESHALB
01900 V00 DESJENIGEN
01910 V00 DESSELBEN
01920 VK0 DESSEN
01930 A00 DESSENTHALBEN
01940 A00 DESSENTWEGEN
01950 A00 DESTO
01960 A00 DESWEGEN
01970 Y00 DICH
01980 IVK DIE
01990 V00 DIES
02000 V00 DIESE
02010 V00 DIESELBEN
02020 V00 DIESELBE
02030 V00 DIESEM
02040 V00 DIESEN
02050 V00 DIESER
02060 V00 DIESES
02070 A00 DIESFALLS
02080 A00 DIESMAL
```

```
02090 AP0 DIESSEITS
02100 Y00 DIR
02110 AN0 DOCH
02120 A00 DORT
02130 A00 DORTHER
02140 A00 DORTHERAUS
02150 A00 DORTHIN
02160 A00 DORTHINAB
02170 A00 DORTHINAUF
02180 A00 DORTHINAUS
02190 A00 DORTHINUNTER
02200 A00 DORTZULANDE
02210 B00 DRAN
02220 B00 DRAUF
02230 B00 DRAUS
02240 A00 DRAUS*EN
02250 B00 DREIN
02260 B00 DRIN
02270 A00 DRINNEN
02280 A00 DRITTENS
02290 A00 DROBEN
02300 A00 DRU*BEN
02310 B00 DRUM
02320 B00 DRUNTEN
02330 B00 DRUNTER
02340 Y00 DU
02350 PA0 DURCH
02360 A00 DURCHAUS
02370 A00 DURCHEINANDER
02380 G00 DURCHS
02390 A00 DURCHWEG
02400 A00 DURCHWEGS
02410 A00 EBENDA
02420 A00 EBENDAHER
02430 A00 EBENDAHIN
02440 A00 EBENDARUM
02450 V00 EBENDER
02460 V00 EBENDIE
02470 V00 EBENDAS
02480 V00 EBENDERSELBE
02490 V00 EBENDIESELBE
02500 V00 EBENDASSELBE
02510 A00 EBENDESHALB
02520 A00 EBENDESWEGEN
02530 A00 EBENFALLS
02540 A00 EBENSO
02550 V00 EBENSOLCHER
02560 V00 EBENSOLCHE
02570 V00 EBENSOLCHES
02580 AN0 EHE
02590 A00 EHEDEM
02600 A00 EHEMALS
02610 A00 EHER
02620 A00 EIGENS
02630 S00 EIGENEM
02640 S00 EIGENEN
02650 S00 EIGENER
02660 S00 EIGENES
02670 S00 EIGENE
02680 A00 EILENDS
02690 JS0 EIN
02700 JS0 EINE
02710 JS0 EINEM
02720 JS0 EINEN
02730 JS0 EINER
02740 A00 EINERSEITS
02750 JS0 EINES
02760 C00 EINHER
02770 V00 EINIGE
02780 V00 EINIGEM
02790 V00 EINIGEN
02800 A00 EINIGERMAS*EN
02810 V00 EINIGES
02820 AP0 EINSCHLIES*LICH
02830 A00 EINST
02840 A00 EMPOR
02850 R00 ENTGEGEN
02860 AR0 ENTLANG
02870 CR0 ENTSPRECHEND
02880 N00 ENTWEDER
02890 Y00 ER
02900 A00 ERSTENS
02910 A00 ERST
02920 Y00 ES
02930 S00 ETLICHE
02940 S00 ETLICHEN
02950 S00 ETLICHER
02960 A00 ETWA
02970 XA0 ETWAS
02980 Y00 EUCH
02990 YU0 EUER
03000 U00 EUERN
03010 U00 EURE
03020 U00 EUREM
03030 U00 EUREN
03040 U00 EURER
03050 A00 EURERSEITS
03060 U00 EURES
03070 X00 EURESGLEICHEN
03080 N00 FALLS
03090 A00 FAST
03100 A00 FERNAB
03110 AZO FEST
03120 A00 FERNERHIN
03130 A00 FOLGENDERWEISE
03140 A00 FORT
03150 A00 FORTAB
03160 A00 FORTAN
03170 A00 FORTHIN
03180 P00 FU*R
03190 G00 FU*RS
03200 P00 GEGEN
03210 A00 GEGENEINANDER
03220 AOR GEGENU*BER
03230 AZ0 GEGENWA*RTIG
03240 R00 GENA*S*
03250 A00 GENUG
03260 A00 GERN
03270 A00 GERNE
03280 A00 GESCHWEIGE
03290 CQ0 HALBER
03300 A00 HER
03310 A00 HERAB
03320 A00 HERAN
03330 A00 HERAUF
03340 A00 HERAUS
03350 A00 HERBEI
03360 A00 HEREIN
03370 A00 HERFU*R
03380 A00 HERNACH
03390 AQ0 HERU*BER
03400 A00 HERUM
03410 A00 HERUNTER
03420 A00 HERVOR
03430 A00 HERZU
03440 A00 HEUTE
03450 A00 HEUTZUTAGE
03460 A00 HIER
03470 A00 HIERBEI
03480 A00 HIERFU*R
03490 A00 HIERHER
03500 A00 HIERHIN
03510 A00 HIERMIT
03520 A00 HIERSELBST
03530 A00 HIERZU
03540 A00 HIN
03550 A00 HINAB
03560 A00 HINAUF
03570 A00 HINAN
03580 A00 HINAUS
03590 A00 HINDURCH
03600 A00 HINEIN
03610 A00 HINSICHTLICH
03620 A00 HINTAN
03630 A00 HINTEN
03640 A00 HINTENAN
03650 A00 HINTENDREIN
03660 A00 HINTENHERUM
03670 A00 HINTENNACH
03680 A00 HINTENU*BER
03690 CP0 HINTER
03700 P00 HINTERM
03710 P00 HINTERN
03720 P00 HINTERS
03730 A00 HINU*BER
03740 A00 HINUNTER
03750 A00 HINWEG
03760 A00 HINZU
03770 A00 HO*CHSTENS
03780 Y00 ICH
03790 Y00 IHM
03800 Y00 IHN
03810 YC0 IHNEN
03820 YU0 IHR
03830 UC0 IHRE
03840 U00 IHREM
03850 U00 IHREN
03860 YU0 IHRER
03870 A00 IHRERSEITS
03880 U00 IHRES
03890 X00 IHRESGLEICHEN
03900 G00 IM
03910 A00 IMMER
03920 A00 IMMERDAR
03930 A00 IMMERFORT
03940 A00 IMMERHIN
03950 A00 IMMERZU
03960 A00 INEINANDER
03970 P00 IN
03980 AN0 INDEM
03990 P00 INFOLGE
04000 A00 INFOLGEDESSEN
04010 P00 INMITTEN
04020 A00 INNE
04030 A00 INNEN
04040 AP0 INNERHALB
04050 G00 INS
04060 A00 INSBESONDERE
```

```
04070 A00 INSGEHEIM
04080 A00 INSGEMEIN
04090 A00 INSGESAMT
04100 AN0 INSOFERN
04110 AN0 INSOWEIT
04120 A00 INZWISCHEN
04130 A00 IRGEND
04140 S00 IRGENDEIN
04150 S00 IRGENDEINE
04160 S00 IRGENDEINEM
04170 S00 IRGENDEINEN
04180 S00 IRGENDEINER
04190 S00 IRGENDEINES
04200 S00 IRGENDWELCH
04210 S00 IRGENDWELCHE
04220 S00 IRGENDWELCHEM
04230 S00 IRGENDWELCHEN
04240 S00 IRGENDWELCHER
04250 S00 IRGENDWELCHES
04260 S00 IRGENDWAS
04270 A00 IRGENDWIE
04280 A00 IRGENDWO
04290 A00 IRGENDWANN
04300 A00 JA
04310 A00 JAWOHL
04320 A00 JAHRAUS
04330 A00 JAHREIN
04340 A00 JE
04350 A00 JEHER
04360 A00 JEWEILS
04370 S00 JEDE
04380 S00 JEDER
04390 S00 JEDERMANN
04400 S00 JEDEM
04410 S00 JEDEN
04420 S00 JEDES
04430 A00 JEDERZEIT
04440 A00 JEDESMAL
04450 A00 JEDOCH
04460 S00 JEGLICH
04470 S00 JEGLICHE
04480 S00 JEGLICHEM
04490 S00 JEGLICHEN
04500 S00 JEGLICHER
04510 S00 JEGLICHES
04520 A00 JEMALS
04530 S00 JEMAND
04540 S00 JEMANDEM
04550 S00 JEMANDEN
04560 S00 JEMANDS
04570 V00 JENE
04580 V00 JENEM
04590 V00 JENER
04600 V00 JENES
04610 P00 JENSEITS
04620 A00 JETZT
04630 A00 KAUM
04640 S00 KEIN
04650 S00 KEINE
04660 S00 KEINEM
04670 S00 KEINEN
04680 S00 KEINER
04690 S00 KEINES
04700 A00 KEINMAL
04710 P00 KRAFT
04720 AZ0 LANGE
04730 A00 LA*NGELANG
04740 PA0 LA*NGS
04750 A00 LA*NGST
04760 A00 LA*NGSTENS
04770 CAP LAUT
04780 A00 LETZTENS
04790 A00 LINKS
04800 CA0 LOS
04810 S00 MAN
04820 S00 MANCH
04830 S00 MANCHE
04840 S00 MANCHEM
04850 S00 MANCHEN
04860 S00 MANCHER
04870 S00 MANCHES
04880 A00 MANCHMAL
04890 P00 MANGELS
04900 A00 MEHR
04910 S00 MEHRERE
04920 S00 MEHREREN
04930 S00 MEHRERER
04940 S00 MEHRERES
04950 A00 MEHRMALS
04960 U00 MEIN
04970 U00 MEINE
04980 U00 MEINEM
04990 U00 MEINEN
05000 UY0 MEINER
05010 U00 MEINES
05020 X00 MEINESGLEICHEN
05030 A00 MEINETWEGEN
05040 A00 MEINETHALBEN
05050 A00 MEISTENS
05060 Y00 MICH
05070 A00 MINDESTENS
05080 A00 MINUS
05090 Y00 MIR
05100 D00 MITAN
05110 D00 MITU*BER
05120 D00 MITEIN
05130 D00 MITUNTER
05140 P00 MIT
05150 A00 MITTAGS
05160 P00 MITTELS
05170 A00 MITTEN
05180 A00 MITTENDREIN
05190 A00 MITTENDRIN
05200 A00 MITTENDRUNTER
05210 A00 MITTENDURCH
05220 A00 MITTERNACHTS
05230 A00 MITTLERWEILE
05240 P00 MITSAMT
05250 A00 MO*GLICHST
05260 A00 MO*GLICHENFALLS
05270 A00 MORGEN
05280 A00 MORGENS
05290 RA0 NACH
05300 N00 NACHDEM
05310 A00 NACHHER
05320 A00 NACHMALS
05330 A00 NACHMITTAGS
05340 ACP NA*CHST
05350 A00 NA*CHSTDEM
05360 A00 NA*CHSTENS
05370 A00 NACHTS
05380 A00 NACHTSU*BER
05390 A00 NAHEBEI
05400 A00 NAHEZU
05410 A00 NAHENS
05420 AZ0 NATU*RLICH
05430 P00 NEBEN
05440 A00 NEBENAN
05450 A00 NEBENEINANDER
05460 A00 NEBENHER
05470 P00 NEBST
05480 A00 NEIN
05490 A00 NEUERDINGS
05500 A00 NEUESTENS
05510 N00 NICHT MEHR
05520 A00 NICHT
05530 S00 NICHTS
05540 A00 NIEMALS
05550 S00 NIEMAND
05560 S00 NIEMANDEM
05570 S00 NIEMANDEN
05580 S00 NIEMANDS
05590 AN0 NOCH
05600 A00 NOCHMALS
05610 A00 NUN
05620 A00 NUR
05630 APN OB
05640 A00 OBEN
05650 A00 OBENAN
05660 A00 OBENAUF
05670 A00 OBENDRAUF
05680 A00 OBENDREIN
05690 A00 OBENHIN
05700 P00 OBERHALB
05710 N00 OBGLEICH
05720 N00 OBSCHON
05730 N00 OBWOHL
05740 N00 ODER
05750 PN0 OHNE
05760 A00 OHNEDEM
05770 A00 OHNEHIN
05780 A00 OHNEDIES
05790 A00 OHNGEFA*HR
05800 P00 PER
05810 A00 PLUS
05820 P00 PRO
05830 A00 RECHTS
05840 APO SAMT
05850 A00 SCHLIES*LICH
05860 A00 SCHON
05870 A00 SEHR
05880 *00 SEIN
05890 U00 SEINE
05900 U00 SEINEM
05910 U00 SEINEN
05920 UY0 SEINER
05930 A00 SEINERSEITS
05940 X00 SEINESGLEICHEN
05950 U00 SEINES
05960 A00 SEINETWEGEN
05970 A00 SEINETHALBEN
05980 A00 SEINETWILLEN
05990 PN0 SEIT
06000 A00 SEITAB
06010 AN0 SEITDEM
06020 A00 SEITHER
06030 A00 SEITLINGS
06040 P00 SEITENS
```

```
06050 A00 SELBST
06060 W00 SICH
06070 Y00 SIE
06080 *03 SO
06090 AN0 SOBALD
06100 A00 SODANN
06110 A00 SOEBEN
06120 N00 SOFERN
06130 A00 SOFORT
06140 A00 SOGAR
06150 A00 SOGLEICH
06160 A00 SOHIN
06170 N00 SOLANGE
06180 S00 SOLCHEM
06190 S00 SOLCHEN
06200 S00 SOLCHER
06210 S00 SOLCHES
06220 S00 SOLCHE
06230 A00 SOMIT
06240 A00 SONACH
06250 A00 SONDERN
06260 CAP SONDER
06270 A00 SONST
06280 A00 SONSTWIE
06290 A00 SONSTWO
06300 A00 SOOFT
06310 AN0 SOSEHR
06320 N00 SOVIEL
06330 AN0 SOWEIT
06340 AN0 SOWENIG
06350 N00 SOWIE
06360 A00 SOWIESO
06370 N00 SOWOHL
06380 A00 SOZUSAGEN
06390 PN0 STATT
06400 A00 STETS
06410 A00 TAGAUS
06420 A00 TAGEIN
06430 AZ0 TATSA*CHLICH
06440 A00 TEILS
06450 P00 TROTZ
06460 AN0 TROTZDEM
06470 A00 U*BERALL
06480 APO U*BER
06490 A00 U*BERAUS
06500 A00 U*BERDAS
06510 A00 U*BERDEM
06520 A00 U*BERDIES
06530 A00 U*BEREIN
06540 A00 U*BEREINANDER
06550 G00 U*BERM
06560 G00 U*BERN
06570 G00 U*BERS
06580 APO UM
06590 A00 UMHER
06600 A00 UMHIN
06610 G00 UNS
06620 P00 UNBESCHADET
06630 M00 UND
06640 AP0 UNFERN
06650 CPN UNGEACHTET
06660 A00 UNGEFA*HR
06670 A00 UNLA*NGST
06680 Y00 UNS
06690 UY0 UNSER
06700 U00 UNSERE
06710 U00 UNSEREM
06720 U00 UNSEREN
06730 U00 UNSERER
06740 U00 UNSERES
06750 A00 UNSERERSEITS
06760 X00 UNSERESGLEICHEN
06770 A00 UNSERSEITS
06780 X00 UNSRESGLEICHEN
06790 U00 UNSRE
06800 U00 UNSREM
06810 U00 UNSREN
06820 U00 UNSRER
06830 U00 UNSRES
06840 A00 UNTEN
06850 A00 UNTENAN
06860 A00 UNTENHER
06870 A00 UNTENHIN
06880 CPO UNTER
06890 P00 UNTERHALB
06900 P00 UNTERM
06910 P00 UNTERN
06920 P00 UNTERS
06930 APO UNWEIT
06940 P00 VERMITTELS
06950 P00 VERMO*GE
06960 A00 VIELMEHR
06970 A00 VIELLEICHT
06980 S00 VIELER
06990 ZS0 VIELEN
07000 S00 VIELE
07010 AZ0 VIEL
07020 A00 VOLLAUF
07030 A00 VOLLENDS
07040 G00 VOM
07050 P00 VON
07060 A00 VONEINANDER
07070 APO VOR
07080 A00 VORAB
07090 A00 VORAN
07100 A00 VORAUF
07110 A00 VORAUS
07120 P00 VORBEHALTLICH
07130 A00 VORBEI
07140 A00 VORDEM
07150 A00 VOREINANDER
07160 A00 VORERST
07170 A00 VORHER
07180 A00 VORHIN
07190 A00 VORHINEIN
07200 G00 VORM
07210 A00 VORN
07220 A00 VORNAN
07230 A00 VORNE
07240 A00 VORNHEREIN
07250 A00 VORNU*BER
07260 G00 VORS
07270 A00 VORU*BER
07280 A00 VORWA*RTS
07290 PN0 WA*HREND
07300 A00 WA*HRENDDEM
07310 A00 WA*HRENDDES
07320 A00 WA*HRENDDESSEN
07330 KT0 WAS
07340 M00 WEDER
07350 N00 WEIL
07360 AD0 WEG
07370 K00 WEGEN
07380 A00 WEITAB
07390 A00 WEITAUS
07400 A00 WEITHER
07410 A00 WEITHIN
07420 TK0 WELCH
07430 TK0 WELCHE
07440 TK0 WELCHEM
07450 TK0 WELCHEN
07460 TK0 WELCHER
07470 TK0 WELCHES
07480 A00 WELCHERLEI
07490 TK0 WEM
07500 A00 WENIG
07510 TK0 WEN
07520 S00 WENIGEM
07530 S00 WENIGEN
07540 S00 WENIGER
07550 S00 WENIGES
07560 A00 WENIGST
07570 A00 WENIGSTENS
07580 N00 WENN
07590 N00 WENNGLEICH
07600 N00 WENNSCHON
07610 TK0 WER
07620 D00 WESHALB
07630 T00 WESSEN
07640 P00 WIDER
07650 DL0 WIE
07660 A00 WIEDER
07670 A00 WIEDERUM
07680 A00 WIEFERN
07690 A00 WIESO
07700 D00 WIEVIEL
07710 D00 WIEVIELMAL
07720 D00 WIEWEIT
07730 N00 WIEWOHL
07740 Y00 WIR
07750 DE0 WO
07760 A00 WOANDERS
07770 NE0 WOBEI
07780 DE0 WODURCH
07790 N00 WOFERN
07800 AE0 WOFU*R
07810 AE0 WOGEGEN
07820 DE0 WOHER
07830 DE0 WOHIN
07840 D00 WOHINAUS
07850 N00 WOHINGEGEN
07860 DE0 WOMIT
07870 A00 WOMO*GLICH
07880 DE0 WONACH
07890 DE0 WORAN
07900 DE0 WORAUF
07910 DE0 WORAUS
07920 DE0 WOREIN
07930 DE0 WORIN
07940 DE0 WORU*BER
07950 DE0 WORUM
07960 DE0 WORUNTER
07970 DE0 WOVON
07980 DE0 WOVOR
07990 DE0 WOWIDER
08000 DE0 WOZU
08010 A00 WOHL
08020 A00 WOHLAUF
```

```
08030 *04 ZU
08040 A00 ZUALLERERST
08050 A00 ZUA*US*ERST
08060 A00 ZUDEM
08070 A00 ZUEINANDER
08080 A00 ZUERST
08090 R00 ZUFOLGE
08100 A00 ZUGRUNDE
08110 P00 ZUGUNSTEN
08120 A00 ZUGUTE
08130 A00 ZUHINTERST
08140 A00 ZULANDE
08150 A00 ZULETZT
08160 AQO ZULIEBE
08170 G00 ZUM
08180 AN0 ZUMAL
08190 A00 ZUMEIST
08200 A00 ZUMINDEST
08210 A00 ZUMUTE
08220 AP0 ZUNA*CHST
08230 A00 ZUNUTZE
08240 A00 ZUOBERST
08250 G00 ZUR
08260 A00 ZURECHT
08270 AO0 ZURU*CK
08280 A00 ZURZEIT
08290 AO0 ZUSAMMEN
08300 P00 ZUSAMT
08310 A00 ZUTEIL
08320 A00 ZUTIEFST
08330 A00 ZUUNTERST
08340 A00 ZUUNGUNSTEN
08350 A00 ZUVIEL
08360 AO0 ZUVOR
08370 A00 ZUVO*RDERST
08380 A00 ZUWEILEN
08390 AOQ ZUWIDER
08400 A00 ZUZEITEN
08410 A00 ZUZU*GLICH
08420 A00 ZWAR
08430 P00 ZWECKS
08440 PO0 ZWISCHEN
08450 AO0 ZWISCHENDURCH
08460 A00 ZWISCHENHER
```

4.3.2.1.2 Les mots outils expressions (.FIXALL(EXPRALL))

Afin de limiter les balayages de la phrase et pour faciliter l'analyse automatique ultérieure, nous avons cherché à repérer les mots-outils disjoints et à les associer dans un même enregistrement.
Le fichier ci-dessous est lu sans tenir compte du signe "@" pour les prépositions, conjonctions de subordination, outils de la comparaison et interrogatifs multitermes, du "#" pour les expressions adverbiales, et du "'" pour les expressions à balance du type "NICHT NUR ... SONDERN AUCH".

.FIXALL(EXPRALL) :

```
00010 .FIXALL(EXPRALL)
00020 00117
00030 00097
00040 00052
00050 06348
00060 N00 @ALS@OB
00070 P00 @AN@$HAND
00080 N00 @ANSTATT@ZU
00090 P00 @AN@$STELLE
00100 N00 @AUCH@WENN
00110 N00 @AUF@DAS*
00120 N00 @AUF@$GRUND
00130 N00 @AUS*ER@DAS*
00140 N00 @AUS*ER@WENN
00150 P00 @BIS@AN
00160 P00 @BIS@AUF
00170 N00 @BIS@DAS*
00180 P00 @BIS@IN
00190 P00 @BIS@NACH
00200 P00 @BIS@ZU
00210 P00 @BIS@ZUM
00220 P00 @BIS@ZUR
00230 L00 @EBENSO@WIE
00240 N00 @EHE@DAS*
00250 N00 @ES@SEI@DENN
00260 N00 @GESCHWEIGE@DAS*
00270 N00 @GESCHWEIGE@DENN
00280 N00 @INSOFERN@ALS
00290 N00 @INSOWEIT@ALS
00300 N00 @JEDESMAL@WENN
00310 N00 @JE@NACH
00320 N00 @KAUM@DAS*
00330 L00 @MEHR@ALS
00340 N00 @NUR@DAS*
00350 N00 @OB@AUCH
00360 N00 @OHNE@DAS*
00370 N00 @SEI@ES
00380 N00 @SELBST@WENN
00390 N00 @SO@DAS*
00400 N00 @STATT@ZU
00410 N00 @STATT@DAS*
00420 L00 @UM@SO
00430 N00 @UND@WENN
00440 P00 @UNWEIT@VON
00450 N00 @WAS@AUCH
00460 T00 @WAS@FU*R@EIN
00470 T00 @WAS@FU*R@EINE
00480 T00 @WAS@FU*R@EINEM
00490 T00 @WAS@FU*R@EINEN
00500 T00 @WAS@FU*R@EINER
00510 T00 @WAS@FU*R@EINES
00520 N00 @WENN@AUCH
00530 N00 @WENN@NICHT
00540 N00 @WIE@WENN
00550 N00 @WO@NICHT
00560 F00 #AB#UND#AN
00570 F00 #AM#MEISTEN
00580 F00 #AB#UND#ZU
00590 F00 #AN#SICH
00600 F00 #AUF#UND#AB
00610 F00 #AUS#UND#EIN
00620 F00 #AUS#ER#ACHT
00630 F00 #BEI#ALLEDEM
00640 F00 #BEI#WEITEM
00650 F00 #DA#JA
00660 F00 #DA#JEDOCH
00670 F00 #DA#ABER
00680 F00 #DARU*BER#HINAUS
00690 F00 #DAS#HEIS*T
00700 F00 #DESTO#BESSER
00710 F00 #DESTO#MEHR
00720 F00 #DESTO#WENIGER
00730 F00 #EIN#UND#AUS
00740 F00 #IMMER#MEHR
00750 F00 #IMMER#NOCH
00760 F00 #IN#ACHT
00770 F00 #JE#UND#JE
00780 F00 #JE#NACHDEM
00790 F00 #NACH#UND#NACH
00800 F00 #NACH#WIE#VOR
00810 F00 #NUR#NOCH
00820 F00 #OHNE#WEITERES
00830 F00 #SCHON#DESWEGEN
00840 F00 #SCHON#LANGE
00850 F00 #SO#SEHR
00860 F00 #TROTZ#ALLEDEM
00870 F00 #UND#SO#WEITER
00880 F00 #VON#ALLEDEM
00890 F00 #VON#ALLEIN
00900 F00 #VON#DA#AB
00910 F00 #VON#DA#AN
00920 F00 #VON#JE
00930 F00 #VOR#ALLEM
00940 K00 "ALS"AUCH
00950 N00 "ALS"DAS*
00960 L00 "DESTO"MEHR
00970 L00 "JE"BESSER
00980 L00 "JE"MEHR
00990 L00 "NICHT"MEHR
01000 K00 "NICHT"NUR
01010 K00 "SONDERN"AUCH
01020 K00 "WIE"AUCH
```

Après repérage dans .SORTIE1.BASE, les segments d'une chaîne-outil[1] sont concaténés sur une même ligne, associés au code prévu.

```
:*0052
0319
0038
0000
0000
0003 014 021 029
0000
0000
0000
00052015660001  P00 MIT
00052015670002  $00 $O*L
00052015680003  N00 ODER
00052015690004  $00 $KOHLE
00052015700005  :01 ALS
00052015710006      PRIMA*REN
00052015720007  $00 $BRENNSTOFFEN
00052015730008      SIND
00052015740009  IVK DAS
00052015750010  F00 #VOR#ALLEN          ←
00052015760011  $00 $SCHWEFELDIOXID
00052015770012  H00 UND
00052015780013  $00 $STICKSTOFFOXID
00052015790014      ,
00052015800015  AH0 DOCH
00052015810016      LIEGT
00052015820017  IVK DIE
00052015830018  $00 $SCHWEFELDIOXID-$EMISSION
00052015840019  A00 BESONDERS
00052015850020      NIEDRIG
00052015860021      ,
00052015870022  N00 WEIL
00052015880023  IVK DIE
00052015890024  $00 $BRENNSTOFFZELLE
00052015900025  P00 GEGEN
00052015910026  $00 $SCHWEFELVERBINDUNGEN
00052015920027      EMPFINDLICH
00052015930028      IST
00052015940029      ,
00052015950030  N00 @S00DAS*          ←
00052015960031  V00 DIESE
00052015970032  P00 IN
00052015980033  IVK DER
00052015990034  $00 $BRENNSTOFF-$AUFBEREITUNGSANLAGE
00052016000035      ENTFERNT
00052016010036      WERDEN
00052016020037      MU*SSEN
00052016030038      .
```

(1) Lorsque les mots-outils sont associés, *so daß...*, nous utilisons le terme de chaîne-outil.

4.3.2.1.3 La partie numérale

Suivie d'une combinaison de deux chiffres, la lettre C permet de générer les codes suivants :

CØØ	nombre, quel qu'il soit, écrit en chiffres
CØ1	cardinal EINS, ZWEI ...
CØ2	ordinal ERSTE, ZWEITE ...
CØ3	multiplicateur VIER/FACH, VIER/FALTIG ...
CØ4	fractionnaire DRITTEL, VIERTEL ...
CØ5	adverbial ERSTENS, ZWEITENS ...
CØ6	répétitif VIERMAL
CØ7	collectif EINERLEI

```
*0048
0028
0028
0000
0000
0002 015 022
0000
0000
0002 003 007
00048014539001      WIRD
00048014540002  Y00 ES
00048014559003      -
00048014560004  PA0 BEI
00048014570005  Z00 LASTABHA*NGIG@EM
00048014580006  $00 $BETRIEB
00048014590007      -
00048014600008  A00 NUR
00048014610009  *04 ZU
00048014620010  C01 VIERZIG          <----
00048014630011  $00 $PROZENT
00048014640012  UY0 SEINER
00048014650013  $00 $NENNLEISTUNG
00048014660014      GENUTZT
00048014670015      ,
00048014680016  *03 SO
00048014690017      VERBRAUCHT
00048014700018  Y00 ES
00048014710019  A00 FAST
00048014720020  C00 12000           <----
00048014730021  $00 $KILOJOULE
00048014740022      ,
00048014750023 WAP0 UM
00048014760024  JS0 EINE
00048014770025  $00 $KILOWATTSTUNDE
00048014780026  *04 ZU
00048014790027      LIEFERN
00048014800028      .
```

Le module **PROLOG** nous mène du fichier .SORTIE1.BASE à trois fichiers de sortie distincts, .TRANSIT1, .TRANSIT2 et .TRANSIT5. Il est en effet indispensable de préparer convenablement la désambiguïsation de la majuscule en tête de la phrase.

.TRANSIT1 représente le texte après intégration des résultats de **PROLOG**, c'est-à-dire, le codage des mots outils unitermes et multitermes, le codage de la partie numérale et le codage des noms (précédés d'une majuscule) à condition qu'ils ne soient pas en tête de phrase, (la majuscule est ici ambiguë). C'est dans ce fichier que seront inclus les résultats du module **VERBAL** pour le traitement ultérieur de la majuscule.

.TRANSIT1 : phrase n°16

```
*0016
0027
0027
0000  .
0000
0002 012 021
0002 002 016
0002 004 018
0000
00016004410001  __  $CARBONAT-$IONEN
00016004420002      (
00016004430003  $00 $C$03(--)
00016004440004      )
00016004450005      BRAUCHEN
00016004460006  JSO EIN
00016004470007  $00 $SALZ
00016004480008  IVK DER
00016004490009  $00 $KOHLENSA*URE
00016004500010  *01 ALS
00016004510011  $00 $ELEKTROLYT
00016004520012      ,
00016004530013  M0+ UND
00016004540014 #APO UM
00016004550015  $00 $SAUERSTOFF-$IONEN
00016004560016      (
00016004570017  $00 $O--
00016004580018      )
00016004590019  *04 ZU
00016004600020      TRANSPORTIEREN
00016004610021      ,
00016004620022      VERWENDET
00016004630023  *05 MAN
00016004640024  JSO EIN
00016004650025      FESTOES
00016004660026  $00 $OXID
00016004670027      .
```

.TRANSIT1 : phrase n°44

```
*0044
0428
0354
0000
0000
0004 010 017 032 043
0000
0000
0000
00044012690000      $
00044012700001  P00 IN
00044012710002      ERSTER
00044012720003  $00 $LINIE
00044012730004      INTERESSIERT
00044012740005  S00 MAN
00044012750006  W00 SICH
00044012760007  A00 HEUTE
00044012770008  P00 FU*R
00044012780009  $00 $BRENNSTOFFZELLEN
00044012790010      ,
00044012800011  IVK DIE
00044012810012  P00 MIT
00044012820013  $00 $PHOSPHORSA*URE
00044012830014  *01 ALS
00044012840015  $00 $ELEKTROLYTEN
00044012850016      ARBEITEN
00044012860017      ,
00044012870018      BESCHA*FTIGT
00044012880019  W00 SICH
00044012890020  P00 IN
00044012900021      KLEINEREM
00044012910022  $00 $UMFANG
00044012920023  A00 AUCH
00044012930024  P00 MIT
00044012940025  $00 $CARBONAT-$SCHMELZEN
00044012950026  *01 ALS
00044012960027  $00 $ELEKTROLYTEN
00044012970028  K00 UND
00044012980029      UNTERSUCHT
00044012990030      FESTE
00044013000031  $00 $ELEKTROLYTE
00044013010032      ,
00044013020033  IVK DIE
00044013030034  $00 $SAUERSTOFF-$IONEN
00044013040035      TRANSPORTIEREN
00044013050036  K00 UND
00044013060037  $00 $ARBEITSTEMPERATUREN
00044013070038  AP0 UM
00044013080039  C01 TAUSEND
00044013090040  $00 $GRAD
00044013100041  $00 $CELSIUS
00044013110042      VERLANGEN
00044013120043      ,
00044013130044  AN0 DOCH
00044013140045      SIND
00044013150046  $00 $BRENNSTOFFZELLEN
00044013160047  PA0 AUF
00044013170048  V00 DIESER
00044013180049  $00 $BASIS
00044013190050  A00 VORERST
00044013200051  AN0 NOCH
00044013210052  A00 NICHT
00044013220053      PRAKTIKABEL
00044013230054      .
```

.TRANSIT2 ne contient que les mots commençant par une minuscule et non codés ainsi que les premiers mots de phrase non codés :

.TRANSIT2 :

```
000140042100032 GELANGEN
000140042200033 MUS*
000150042400001 $SAURE
000150042600003 TRANSPORTIEREN
000150043300010 ALKALISCHEN
000150043500012 WANDERN
000160044100001 $CARBONAT-$IONEN
000160044500005 BRAUCHEN
000160046000029 TRANSPORTIEREN
000160046200022 VERWENDET
000160046500025 FESTES
000170047500007 ERZEUGEN
```

```
000440127100002 ERSTER
000440127300004 INTERESSIERT
000440128500016 ARBEITEN
000440128700018 BESCHA*FTIGT
000440129000021 KLEINEREM
000440129800029 UNTERSUCHT
000440129900030 FESTE
000440130400035 TRANSPORTIEREN
000440130800039 TAUSEND
000440131100042 VERLANGEN
000440131400045 SIND
000440132200053 PRAKTIKABEL
000450132900005 LIEGEN
000450133500011 UMWELTSCHONENDEN
000450134800024 VERWENDEN
000450134900025 LA*S*T
000450135200028 BELIEBIG
000450135300029 GROS*E
000450135500031 ZUSAMMENZUSETZEN
000460135900003 BLEIBT
000460136800012 UNVERA*NDERT
000460137500019 BETRA*CHTLICHE
000460137900023 ERMO*GLICHT
```

.TRANSIT5 rassemble les mots à majuscule à condition qu'ils ne soient pas en tête de phrase. Il sera utilisé pour la désambiguïsation de la majuscule en tête de phrase.

.TRANSIT5

```
0001500427000A $WASSERSTOFF-$IONEN
0001500429000B $H+
0001500434001I $ELEKTROLYTEN
0001500436001J $HYDROXID-$IONEN
0001500438001J $O$H(--)
0001600443000D $C$O3(--)
0001600447000G $SALZ
0001600449000I $KOHLENSA*URE
0001600451001I $ELEKTROLYT
0001600455001P $SAUERSTOFF-$IONEN
0001600457001H $O--
0001600466000Z $OXID
0001700470000C $GLEICHSPANNUNG
0001700474000G $BRENNSTOFFZELLE
0001700482001E $ART
```

```
0004301250000G $BRENNSTOFFZELLE
0004301254001A $WIRKUNGSGRAD
0004301263001J $ELEKTRIZITA*TSNETZ
0004301265002B $KRAFTWERK
0004401272000D $LINIE
0004401278000J $BRENNSTOFFZELLEN
0004401282001D $PHOSPHORSA*URE
0004401284001P $ELEKTROLYTEN
0004401291002C $UMFANG
0004401294002P $CARBONAT-$SCHMELZEN
0004401296002R $ELEKTROLYTEN
0004401300003C $ELEKTROLYTE
0004401393003I $SAUERSTOFF-$IONEN
0004401306003R $ARBEITSTEMPERATUREN
0004401309004A $GRAD
0004401310004B $CELSIUS
0004401315004G $BRENNSTOFFZELLEN
0004401318004J $BASIS
0004501326000C $VORTEILE
0004501328000H $BRENNSTOFFZELLEN
```

4.3.2.2 Le traitement du verbe (VERBAL)

Le module central du logiciel d'analyse fonctionne sur **.TRANSIT2** en entrée. 60 % de ses éléments sont des verbes, le reste des adjectifs ou des adverbes.

Conçu pour le traitement de toute langue source germanique, il se compose de trois programmes importants. Les nombreuses procédures dont une partie n'intervient que pour une langue donnée, ont pour fonction de localiser l'ensemble des formes verbales, de les découper pour reconstituer la base correspondante (nécessaire pour la phase de transfert) et de leur associer un code à quatre positions.

La préparation linguistique de l'étape allemande et sa réalisation informatique achevées, nous avons testé la pertinence de nos méthodes sur le néerlandais puis le luxembourgeois.
Des difficultés spécifiques au néerlandais, (règles orthographiques et nombreuses ambiguïtés dues à l'absence de majuscule) puis le choix de nouvelles techniques de lecture de fichier par variables basées nous ont amené à modifier la présentation des données pour chaque langue et l'ordre de succession des procédures dans le sens d'une rapidité et d'une finesse accrues. Nous donnerons au cours de ce chapitre une illustration de ces tâtonnements.

4.3.2.2.1 Les filtres (.FILTRAL)

La partie terminale des enregistrements de **.TRANSIT2** est comparée aux éléments de **.MORPHAL(ENDUNG)** pour l'allemand, **.MORPHOL (ENDUNG)** pour le néerlandais et **.MORPHLX(ENDUNG)** pour le luxembourgeois. Les formes dont la terminaison n'est pas verbale sont éliminées. 75 % à 80 % de ce que le programme retient est effectivement verbal.

.MORPHAL(ENDUNG) :

```
00010 0166
00020 0030
00030 6634
00040 -A
00050 +AB
00060 +IEB
00070 +OB
00080 +ARB
00090 +UB
00100 -C
00110 +IED
00120 +AND
00130 +IND
00140 +UD
00150 +IRD
00160 +END
00170 +ELND
00180 +ERND
00190 +E
00200 +ALE
00210 +SCHALE
00220 +MALE
00230 +ATE
00240 +RATE
00250 +IMATE
00260 +ICHE
00270 +BLICHE
00280 +GLICHE
00290 +GLEICHE
00300 +SCHLICHE
00310 +STRICHE
00320 +WICHE
00330 +KLICHE
00340 +NLICHE
00350 +ERLICHE
00360 +S*LICHE
00370 +ATLICHE
00380 +UTLICHE
```

.MORPHOL(ENDUNG) :

```
00010 0020
00020 0030
00030 6634
00040 +GA
00050 +STA
00060 +B
00070 -C
00080 +D
00090 +E
00100 +F
00110 +G
00120 -H
00130 -I
00140 +IJ
00150 +K
00160 +L
00170 +M
00180 +EN
00190 +N
00200 -O
00210 +P
00220 -Q
00230 +R
00240 +S
00250 +T
00270 -U
00280 +V
00290 +W
00300 -X
00310 -Y
00320 -Z
```

.MORPHLX(ENDUNG) :

```
00010 00124
00020 0030
00030 6334
00040 A
00050 B
00060 C
00070 +ID
00080 +ED
00090 +DD
00100 +ND
00110 +OD
00120 +RD
00130 +E
00140 -DE
00150 -DE*SE
00160 +EF
00170 +E*F
00180 +RF
00190 +IF
00200 +UF
00210 +AF
00220 +OF
00230 +FF
00240 +NG
00250 -ENG
00260 -KENG
00270 +EG
00280 +IG
00290 +SCH
00300 -BESONNESCH
00310 +CH
00320 -DUERCH
00330 -NACH
00340 -OCH
00350 -SECH
00360 +A*I
00370 +E>I
00380 -DE>I
```

↓

```
00390 +ISCHE
00400 +HEISCHE
00410 +FISCHE
00420 +MISCHE
00430 +FRISCHE
00440 +WISCHE
00450 -EINZELNE
00460 -VIELE
00470 +RAF
00480 +IEF
00490 +IFF
00500 +OFF
00510 +ALF
00520 +ARF
00530 +HUF
00540 +AG
00550 +IEG
00560 +ANG
00570 +ING
00580 +OG
00590 +UG
00600 +ARG
00610 +OH
00620 +IEH
00630 +AH
00640 +CH
00650 +ICH
00660 +BLICH
00670 +GLICH
00680 +SCHLICH
00690 +STRICH
00700 +WICH
00710 -ISCH
00720 -HOCH
00730 -I
00740 -J
00750 +UK
00760 +AK
00770 +OLK
00780 +ACK
00790 +ANK
00800 +AHL
00810 +OLL
00820 +IEL
00830 -VIEL
00840 +ILL
00850 +OHM
00860 +AM
00870 +AHM
00880 +AMM
00890 +TEM
00900 +ENEM
00910 +NDEM
00920 +EN
00930 +ICHEN
00940 +EICHEN
00950 +BLICHEN
```

```
00390 -EWE>I
00400 -HE>I
00410 -WE>I
00420 +EI
00430 -HEI
00440 +I
00450 J
00460 +AK
00470 +OK
00480 +NK
00490 +EK
00500 +IK
00510 +AL
00520 +IL
00530 +LL
00540 -ALL
00550 -WELL
00560 +EL
00570 +OL
00580 +UL
00590 +*L
00600 +IN
00610 +MM
00620 +AN
00630 +EN
00640 -DEN
00650 -DEENEN
00660 -DEEN
00670 -ALLEN
00680 -EEN
00690 -EISEN
00700 -DE*SEN
00710 +IN
00720 +UN
00730 -VUN
00740 +ON
00750 +NN
00760 -DANN
00770 -WANN
00780 -ENN
00790 +*N
00800 O
00810 P
00820 Q
00830 +AR
00840 +ER
00850 -DER
00860 -DE*SER
00870 -ABER
00880 -DEER
00890 -E*RRER
00900 -E*NNER
00910 -EISER
00920 -ENGER
00930 -MER
00940 -ODER
00950 -ESOUQUER
```

```
00960 +GLICHEN
00970 +SCHLICHEN
00980 +STRICHEN
00990 +WICHEN
01000 +KLICHEN
01010 +NLICHEN
01020 +ERLICHEN
01030 +S*LICHEN
01040 +ATLICHEN
01050 +UTLICHEN
01060 +ISCHEN
01070 +HEISCHEN
01080 +FISCHEN
01090 +MISCHEN
01100 +FRISCHEN
01110 +WISCHEN
01120 +ALEN
01130 +SCHALEN
01140 +MALEN
01150 +ATEN
01160 +RATEN
01170 +MATEN
01180 +ELN
01190 +ERN
01200 -EINZELN
01210 -FERN
01220 +EIN
01230 +SEIN
01240 +NN
01250 -EINZELNEN
01260 -VIELEN
01270 +AN
01280 +GETAN
01290 -O
01300 -P
01310 -Q
01320 +UHR
01330 +OR
01340 +AR
01350 +UR
01360 +ENER
01370 +TER
01380 -WEITER
01390 +ENDER
01400 +IES
01410 +NAS
01420 +LAS
01430 +CHS
01440 +NDES
01450 +ENES
01460 +TES
01470 +T
01480 -ST
01490 +A*ST
01500 +EIST
01510 -MEIST
01520 +IEST
01530 +KIEST
01540 +LIEST
```

↓

```
01550 +EST
01560 +GENEST
01570 +RST
01580 +BIRST
01590 +BARST
01600 +BORST
01610 +*CHST
01620 +WA*CHST
01630 -SCHST
01640 -U
01650 -V
01660 -W
01670 -X
01680 -Y
01690 +OLZ
```

```
00960 -MER
00970 +*R
00980 +AS
00990 +SS
01000 +*S
01010 -DE*S
01020 +IS
01030 -DIS
01040 -EIS
01050 +ES
01060 -ALLES
01070 +T
01080 +AT
01090 -DAT
01100 -MAT
01110 +IT
01120 +OT
01130 +UT
01140 +TT
01150 -DATT
01160 +RT
01170 +LT
01180 +*T
01190 -E*T
01200 -NE*T
01210 +U
01220 -ESOU
01230 V
01240 W
01250 X
01260 Y
01270 Z
```

Lorsque la terminaison du mot testé figure dans ces tableaux précédée du signe "+", elle est potentiellement verbale, précédée du signe "-", elle est rejetée.

4.3.2.2.2 Les verbes d'emprunt (.VERBAL1)

Les langues germaniques que nous analysons ont en commun d'absorber une quantité non négligeable de verbes "romans", les empruntant tantôt au français, tantôt au latin. -IEREN pour l'allemand, -ERA pour le suédois, -EREN pour le néerlandais, -ERE pour le danois et le norvégien, -EIRE pour le luxembourgeois sont les dénominateurs communs qui autorisent une première étude sans recours aux dictionnaires de racines. L'analyse s'appuie essentiellement sur une reconnaissance fine de la partie terminale, la levée des interférences avec les formes germaniques (*halbieren, gieren, verlieren, fieren, amtieren, stieren, zieren....* pour l'allemand) et le découpage des préverbes, peu fréquents il est vrai.

Les tableaux de désinences qui suivent correspondent à trois niveaux d'analyse différents :

.MORPHLX(DESI) réunit les désinences luxembourgeoises sans autres indications.
.MORPHOL(DESI) permet de différencier les désinances classées selon le signe diacritique qui les précède: "@" pour les participes déclinés, "$" pour le participe présent non décliné, '%' pour l'indicatif, '*' pour le prétérit.
.MORPHAL(DESI) représente la version la plus récente : les désinences sont associées à des codes de quatre chiffres sans lesquels il serait impossible de décrire correctement la forme "EN" (et "IER/EN") rencontrée à l'infinitif (1), à l'indicatif présent (3), à l'indicatif passé (4) et au participe passé (8) .
L'incompatibilité de certaines données apparaît au découpage, qui permet de simplifier le code : L'absence ou la présence du "GE", morphème du participe passé, infirme ou confirme, pour la terminaison "EN", et selon la structure du verbe, la configuration du code. Il en va de même pour les désinences "T" et "ET" dans le cas des verbes réguliers.

.MORPHAL(DESI) :

```
00010 0046
00020 0032
00030 0039
00040 6334
00050 3000E
00060 3800T
00070 1300N
00080 1348EN
00090 3890ET
00100 4700TE
00110 6000ND
00120 6000END
00130 5000NDE
00140 7000ENE
00150 4700TEN
00160 7000TER
00170 7000TEM
00180 7000TES
00190 A700ETE
00200 5000ENDE
00210 5000NDER
00220 5000NDEM
00230 5000NDEN
00240 5000NDES
00250 7000ENEM
```

.MORPHOL(DESI) :

```
00010 0020
00020 0030
00030 6334
00040 %E
00050 %N
00060 %T
00070 $D
00080 %EN
00090 *DE
00100 *TE
00110 *DEN
00120 *TEN
00130 $ND
00140 %E*N
00150 $END
00160 @ENDE
00170 @NDE
00180 @TES
00190 @DES
00200 @NES
00210 @ENES
00220 @ENEN
00230 @ENDEN
```

.MORPHLX(DESI) :

```
00010 0010
00020 0030
00030 6334
00040 +ENEM
00050 +ENER
00060 +ENEN
00070 +ETEN
00080 +ETER
00090 +ETEM
00100 +ENE
00110 +ETE
00120 +TEN
00130 +TER
00140 +TEM
00150 +E*N
00160 +EN
00170 +ET
00180 +TE
00190 +E
00200 +N
00210 +T
```

```
00260 7000ENEN
00270 7000ENER
00280 7000ENES
00290 4700ETEN
00300 7000ETER
00310 7000ETEM
00320 7000ETES
00330 5000ENDER
00340 5000ENDEM
00350 5000ENDEN
00360 5000ENDES
00370 7000IERTER
00380 7000IERTEM
00390 4700IERTEN
00400 7000IERTES
00410 4700IERTE
00420 3800IERT
00430 5000IERENDEM
00440 5000IERENDEN
00450 5000IERENDER
00460 5000IERENDES
00470 5000IERENDE
00480 6000IEREND
00490 1348IEREN
00500 3000IERE
```

4.3.2.2.3 Les verbes allemands (.VERBAL2)

L'analyse de la forme potentiellement verbale s'effectue, cette fois ci, par la gauche, et en trois temps :

- reconnaissance et découpage de la préverbation
- reconnaissance de la racine verbale
- vérification du résidu et codage

4.3.2.2.3.1 Etude de la préverbation

Dans un but de clarté, nous conviendrons d'appeler préverbes dans ce chapitre, ce que l'on nomme ailleurs particule séparable, inséparable ou mixte, et qui existe, bien que ne fonctionnant pas toujours de la même façon, dans les autres langues germaniques.

- *séparable/inséparable* : il n'y a pas lieu de rechercher dans cette étape les préverbes séparables disjoints, ces derniers n'étant pas systématiquement rejetés en fin de proposition. L'analyse syntaxique seule permettra, en fin d'analyse, de repérer ces préverbes et de les associer au verbe correspondant. PROLOG leur a adjoint le code 'O'.

ex : dans .FIXALL(OUTALL)

Ø514Ø - POØ MIT

Si une telle occurrence n'introduit pas un groupe prépositionnel, son code sera désambiguïsé : POØ --> OØØ

Les fichiers de préverbes utilisés remplissent une double fonction :
- les préverbes sont précédés du signe "+" et suivis du signe "%" (pour tenir compte du caractère blanc). +GE% représente également le "GE" du participe
- les enregistrements précédés du signe "-" éliminent les risques de confusion dans le cas de certaines racines.

ex: -ANTW% évite d'éliminer le verbe antworten
-GESTALT% évite le découpage d'un "GE" préverbe inséparable
-GEBRAUCH% évite le découpage d'un "GE" ambigu, traité ultérieurement

.MORPHAL(PREFI) :

```
00010 0033
00020 0176
00030 0078
00040 0049
00050 0034
00060 0030
00070 6334
00080 +AB%
00090 +AN%
00100 -ANTW%
00110 -ANGELN%
00120 -ANGELT%
00130 -ANGELS%
00140 -ANGLE %
00150 -ANKERN%
00160 -ANKERT%
00170 -ANKERE%
00180 -ANKERS%
00190 +BE%
00200 -BEC%
00210 -BERG%
00220 -BERS%
00230 -BESS%
00240 -BEHR%
00250 -BEBE%
00260 -BEBT%
00270 -BEBS%
00280 -BETT%
00290 -BEUG%
00300 -BEUL%
00310 -BEUT%
00320 -BELL%
00330 -BELF%
00340 -BEIZ%
00350 -BETEN%
00360 -BETET%
00370 -BETES%
00380 -BEWEG%
00390 -BEFREI%
00400 -BEGU+NS%
```

.MORPHOL(PREFI) :

```
00010 0125
00020 0060
00030 6041
00040 0013
00050 0007
00060 0050
00070 6334
00080 +AF%
00090 -AFROND%
00100 +BE%
00110 -BEDAAR%
00120 -BEDRI%
00130 -BEDRO%
00140 -BENODI%
00150 -BEUK%
00160 -BEUR%
00170 -BEGRAAF%
00180 -BEGI%
00190 -BEGO%
00200 -BEGRENZ%
00210 -BELL%
00220 -BEEF%
00230 -BEVAT%
00240 -BEEL0%
00250 -BEVEEL%
00260 -BEVEL%
00270 -BEVIND%
00280 -BEVRIJD%
00290 -BENG%
00300 -BETEER%
00310 -BETER%
00320 +ER%
00330 -EREN %
00340 -ERF%
00350 -ERV%
00360 -ERVAREN%
00370 -ERGER%
00380 +GE%
00390 -GEBRUIKEN
00400 -GEBEUR
```

.MORPHLX(PREFI) :

```
00010 0127
00020 0097
00030 0068
00040 0032
00050 0027
00060 0003
00070 0037
00080 0029
00090 6334
00100 +A%
00110 -AFF%
00120 -A+A+%
00130 -AKER%
00140 -A+IF%
00150 -A+NG%
00160 -A+NTW%
00170 +U%
00180 -U+B%
00190 +AN%
00200 +BE%
00210 -BEAFL0%
00220 -BEET%
00230 -BEEN%
00240 -BEEZ%
00250 -BEOU%
00260 -BEFR%
00270 -BEGAA%
00280 -BEGANN%
00290 -BEGE>%
00300 -BEGO<%
00310 -BETOU%
00320 -BEWA<LT%
00330 -BEWE%
00340 -BEWE+LL%
00350 -BEWII%
00360 -BEOHER%
00370 -BE>%
00380 -BE>%
00390 -BE+LZ%
00400 -BENG%
```

```
00410 -BEFEHL%
00420 -BEFIE%
00430 -BEFAHL%
00440 -BEFORL%
00450 -BEFA*HL%
00460 -BEGIN%
00470 -BEGANN%
00480 -BEGONN%
00490 -BEFLEI%
00500 -BEFLI%
00510 -BEWOG%
00520 -BEREIT%
00530 -BEIS*%
00540 +GE%
00550 -GEBRECH%
00560 -GEBRICH%
00570 -GEBROCH%
00580 -GEDENK%
00590 -GEDACH%
00600 -GERINN%
00610 -GERANN%
00620 -GERONN%
00630 -GEBIET%
00640 -GEBOT%
00650 -GEFRIER%
00660 -GEFROR%
00670 -GESTEH%
00680 -GESTAND%
00690 -GEFALL%
00700 -GEFIEL%
00710 -GERAT%
00720 -GERIET%
00730 -GEBRAUCH%
00740 -GEDULD%
00750 -GEHORCH%
00760 -GEHO*R%
00770 -GELEIT%
00780 -GELOB%
00790 -GEREICHE %
00800 -GEREICHEN %
00810 -GEREICHT %
00820 -GEREICHTE %
00830 -GEREICHTEN %
00840 -GERUH%
00850 -GESEGN%
00860 -GETRAU%
00870 -GEWAHR%
00880 -GEWA*HR%
00890 -GEZIEH%
00900 -GEREU%
00910 -GELT%
00920 -GESS%
00930 -GEUD%
00940 -GEHR%
00950 -GEGN%
00960 -GELL%
00970 -GERB%
00980 -GEIS%
00990 -GEIZ%
01000 -GEIG%
01010 -GEIF%
01020 -GEHEN%
01030 -GEBEN%
01040 -GEHST%
01050 -GELING%
```

```
00410 -GELD%
00420 -GELOV
00430 -GENEE%
00440 -GEREN%
00450 -GERIE%
00460 -GEER%
00470 -GENE%
00480 -GENER%
00490 -GENA%
00500 -GEUR%
00510 -GEVEN%
00520 -GEZEL%
00530 -GEZETEN%
00540 -GENIE%
00550 -GENOEG%
00560 -GEEF%
00570 -GEEUW%
00580 -GEF%
00590 -GELIJK%
00600 +IN%
00610 -INNER%
00620 +NA%
00630 -NADER%
00640 +ON%
00650 +OH%
00660 +OP%
00670 -OPEN%
00680 +TE%
00690 +AAN%
00700 -AANDACHT%
00710 -AANTAL%
00720 +ANT%
00730 +BIJ%
00740 -BIJT%
00750 +EEN%
00760 +HER%
00770 +LOS%
00780 -LOOS%
00790 +MEE%
00800 +MIS%
00810 -MISS%
00820 +OOR%
00830 +ONT%
00840 +RUG%
00850 +TOE%
00860 +UIT%
00870 -UITNOD%
00880 -UITTE%
00890 +VER%
00900 -VERBEEL%
00910 -VERBETER%
00920 -VERDICHT%
00930 -VERDR%
00940 -VERDO%
00950 -VERDU%
00960 -VERGLET%
00970 -VERGET%
00980 -VERGAT%
00990 -VERGROT%
01000 -VERGROOT%
01010 -VERKLEI%
01020 -VERLIE%
01030 -VERLOR%
01040 -VERMIND%
01050 -VERSL%
```

```
00410 -BE*GE%
00420 -BEGGEN%
00430 -BE*HA%
00440 -BENT %
00450 -BE*NEN %
00460 -BEET%
00470 -BEST%
00480 -BEZU%
00490 -BEII%
00500 +ER%
00510 +GE%
00520 -GE*T%
00530 -GEE%
00540 -GESCHE>I%
00550 -GEFALL%
00560 -GESI%
00570 -GECKE%
00580 +DO%
00590 -DONAT
00600 -DONK%
00610 -DONG%
00620 -DOU %
00630 +HI%
00640 -HINK%
00650 -HICK%
00660 -HIBB%
00670 -HIREN %
00680 +EM%
00690 +NO%
00700 -NOTZ%
00710 +OF%
00720 -OFFRE>%
00730 +OP%
00740 +UN%
00750 +IE%
00760 -IE>I%
00770 -IEI %
00780 -IE>CK%
00790 -IECK%
00800 -IE*MPER%
00810 -IE*NK%
00820 -IENN%
00830 -IE*SS%
00840 +IU%
00850 -IUKUNFT%
00860 -IUSL%
00870 +AUS%
00880 +BEI%
00890 -BEICH%
00900 +BE*%
00910 +BRA%
00920 +BOR%
00930 +BRU%
00940 -BRUDD%
00950 -BRUNN%
00960 +E*R%
00970 -BRUSCH%
00980 +ENT%
00990 +GE*%
01000 +HIN%
01010 +NAI%
01020 +NOI%
01030 -ONS%
01040 +RAF%
01050 +ROF%
```

```
01050 -GELANGE%
01070 -GELUNG%
01080 -GESTATT%
01090 -GERING%
01100 -GEWINN%
01110 -GEWANN%
01120 -GEWONN%
01130 -GEBARE%
01140 -GEBART%
01150 -GEBU*HR%
01160 -GEDEIH%
01170 -GEDIEH%
01180 -GEFA*HR0%
01190 -GELANGT%
01200 -GELANG%
01210 -GELU*ST%
01220 -GENOSS%
01230 -GENO*SS%
01240 -GENIES*%
01250 -GENEH%
01260 -GENU*G%
01270 -GESCHIEH%
01280 -GESCHEH%
01290 -GESCHAH%
01300 -GESELL%
01310 -GESTALT%
01320 -GEWA*LT%
01330 -GEWA*RT%
01340 -GEWO*NN%
01350 -GENES%
01360 -GENAS%
01370 -GENA*S%
01380 -GEBAR %
01390 -GEBAREN%
01400 -GEBA*R%
01410 -GEBIER%
01420 -GEBOR%
01430 -GENA*%
01440 -GENASEN%
01450 -GENAS %
01460 -GENEST %
01470 -GENESE%
01480 +UN%
01490 +ZU%
01500 -ZUC%
01510 -ZUNUTZE %
01520 -ZUPF%
01530 +DA%
01540 -DAC%
01550 -DAU%
01560 -DANK%
01570 -DARB%
01580 -DAMP%
01590 -DAMM%
01600 -DARF%
01610 +ER%
01620 -ERNT%
01630 -ERBT%
01640 -ERBS%
01650 -ERBEN%
01660 -ERDIG%
01670 -ERDES%
01680 -ERDET%
01690 -ERDEN %
01700 -ERDEND%
01710 -ERMUT%
01720 -ERMO*%
01730 -ERBLEI%
01740 -ERBLICH%
|
01050 +VOL%
01070 -VOLGE%
01080 +WAN%
01090 +WEG%
01100 +DOOR%
01110 +DAAR%
01120 +HEEN%
01130 +HIER%
01140 +MEDE%
01150 +NEER%
01160 +OVER%
01170 +STIL%
01180 +VOOR%
01190 +VRIJ%
01200 +WEER%
01210 +WAAR%
01220 -WAARDE%
01230 +BOVEN%
01240 +KWIJT%
01250 +NEVEN%
01260 +ONDER%
01270 +SAMEN%
01280 +TEGEN%
01290 +VOORT%
01300 +BINNEN%
01310 +PLAATS%
01320 +WAARTS%
.
.
.
.
.
01050 +SOS%
01070 +VER%
01080 -VERGLA*%
01090 -VERSLAGH%
01100 -VERGIET%
01110 -VERLE*%
01120 -VERLOET%
01130 -VERSPRIET%
01140 -VERSPRA%
01150 -VERDER%
01160 +VIR%
01170 +ZER%
01180 +ZOU%
01190 +BA*IS%
01200 +BRUH%
01210 +FEST%
01220 +OVER%
01230 +FORT%
01240 +IJVER%
01250 +LAES%
01260 +UECHT%
01270 +FRA*IS%
01280 +ZWEER%
01290 +QUEROH%
01300 +S*NNER%
01310 +EWECHT%
01320 +SURREN%
01330 +RAI*OH%
01340 +HANNER%
01350 +ZRES>OK%
01360 +ZERES>OK%
```

```
01750 -ERKIEZ
01760 -ERKOZ
01770 -ERLO+SCZ
01780 -ERLISCZ
01790 -ERLOSZ
01800 +IMZ
01810 -IMFOLGZ
01820 +OBZ
01830 +UMZ
01840 +AUSZ
01850 +ENTZ
01860 -ENTERTZ
01870 -ENTERNZ
01880 -ENTERSZ
01890 +VERZ
01900 -VEREINZ
01910 -VERLANGZ
01920 -VERMINDZ
01930 -VERGRO+Z
01940 -VERBILLZ
01950 -VERDRIEZ
01960 -VERDROSZ
01970 -VERGESSZ
01980 -VERGIS+Z
01990 -VERGAS+Z
02000 -VERLIERZ
02010 -VERLORZ
02020 -VERDERBZ
02030 -VERDIRBZ
02040 -VERDARBZ
02050 -VERDORBZ
02060 +VORZ
02070 +AUFZ
02080 +BEIZ
02090 -BEICZ
02100 -BEISSZ
02110 -BEIZTZ
02120 -BEIRRZ
02130 -BEIZENZ
02140 +DARZ
02150 -DARBTZ
02160 -DARBSTZ
02170 -DARFSTZ
02180 -DARBENZ
02190 +EINZ
02200 -EINTENZ
02210 -EINTETZ
02220 -EINTESZ
02230 -EINTE Z
02240 -EINIGTZ
02250 -EINIGTZ
02260 -EINENDZ
02270 -EINIGENZ
02280 -EINIGE Z
02290 -EINSAMEZ
02300 -EINSAMSZ
02310 -EINSAMTZ
02320 -EINHEITLZ
02330 +HERZ
02340 -HERRSZ
02350 -HERRLZ
02360 -HERZIGZ
02370 -HERZENZ
02380 -HERZESZ
02390 +HINZ
02400 -HINDRZ
02410 -HINKRZ
02420 -HINKTZ
```

```
02430 -HINDERZ
02440 -HINKENZ
02450 -HINKE Z
02460 +LOSZ
02470 -LOSE Z
02480 -LOSTEZ
02490 -LOSTENZ
02500 +MITZ
02510 -MITTLZ
02520 -MITTELZ
02530 +WEGZ
02540 -WEGTENZ
02550 -WEGTESZ
02560 -WEGTETZ
02570 -WEGENDZ
02580 +ZERZ
02590 -ZERRTZ
02600 -ZERRENDZ
02610 -ZERREN Z
02620 +NACHZ
02630 -NACHTE Z
02640 -NACHTENZ
02650 -NACHTETZ
02660 -NACHTESZ
02670 -NACHLA*SZ
02680 +FORTZ
02690 +FU*RZ
02700 +QUERZ
02710 +FREIZ
02720 -FREIE Z
02730 -FREIET Z
02740 -FREIEN Z
02750 -FREIT Z
02760 -FREITE Z
02770 -FREITEN Z
02780 +MIS*Z
02790 -MIS*T Z
02800 +WEITZ
02810 -WEITE Z
02820 -WEITET Z
02830 -WEITEN Z
02840 -WEITETE Z
02850 -WEITETEN Z
02860 -WEITERN Z
02870 -WEITERT Z
02880 -WEITERTE Z
02890 -WEITERTEN Z
02900 -WEITERE Z
02910 +FESTZ
02920 -FESTE Z
02930 -FESTER Z
02940 -FESTES Z
02950 -FESTEN Z
02960 -FESTEn Z
02970 -FESTIGZ
02980 +KENNZ
02990 -KENNEn Z
03000 -KENNE Z
03010 -KENNT Z
03020 +U*BERZ
03030 +ANDERZ
03040 +DURCHZ
03050 +GEGENZ
03060 +NEBENZ
03070 +RU*CKZ
03080 -RU*CKE Z
03090 -RU*CKT Z
03100 -RU*CKENZ
03110 -RU*CKTE Z
```

```
03120 -RU*CKTES%
03130 -RU*CKTEN%
03140 +STATT%
03150 +UNTER%
03160 +WIDER%
03170 -WIDERN %
03180 -WIDERE %
03190 -WIDERT %
03200 -WIDERTE %
03210 -WIDERTEN %
03220 +RECHT%
03230 -RECHTE %
03240 -RECHTER %
03250 -RECHTES %
03260 -RECHTEM %
03270 -RECHTEn %
03280 -RECHTIG %
03290 +WA*HR
03300 -WA*HRE %
03310 -WA*HRET %
03320 -WA*HREn %
03330 -WA*HRT %
03340 -WA*HRTE %
03350 -WA*HRTEN %
03360 +SAMMEN%
03370 +NIEDER%
03380 +WA*RTS%
03390 +WEITER%
03400 +WIEDER%
```

4.3.2.2.3.2 Repérage de la racine verbale

Afin de ne pas multiplier les petits tableaux, nous avons classé les verbes en deux catégories (morphologiques), pour l'allemand, le néerlandais et le luxembourgeois.

Par opposition aux verbes réguliers, les verbes irréguliers allemands et néerlandais répondent au moins à une des caractéristiques suivantes :

- Ils modifient la voyelle de leur radical au prétérit ou au participe passé
- Ils présentent un participe passé en **-en** ou **-n**.

Ceci inclut *les auxiliaires* :

- SEIN, WERDEN
- ZIJN, HEBBEN

les "préterito-présents" :

-Können, dürfen, müssen, mögen
-Kunnen, moeten, mogen, willen, zullen

les *"mixtes"* :

-brennen, kennen, denken, bringen, nennen, rennen, senden, wenden
-backen, scheiden. (imparfait régulier et participe en **-en**).

Aux quelque vingt verbes qui appartiennent à cette famille, il faut ajouter une série de verbes qui présentent un prétérit avec modification de la voyelle du radical et un participe régulier : brengen, denken, dunken, jagen, kopen, pflegen, vragen...

La distinction régulier-irrégulier vaut également pour le suédois :

régulier : - le radical ne subit aucune alternance vocalique
- le prétérit se distingue par la présence d'un suffixe à dentale : **-de, -te, -dde**

irrégulier : - le radical modifie sa voyelle et le prétérit n'a pas de désinence

Pour le danois et le norvégien :

régulier :
- prétérit **-ede**, participe **-et**
- prétérit **-te**, participe **-t** avec ou sans métaphonie

- prétérit	**-et**,	participe	**-et**
	-te,		**-t**
	-de,		**-d**
	-dde,		**-dd**

irrégulier : désinence Ø au prétérit et changement vocalique au prétérit et au participe passé

Ce partage, s'il a le défaut d'effacer les particularités de chaque langue, a l'avantage de se prêter à une exploitation simple, sûre et rapide. A ce stade de l'analyse, l'essentiel n'est pas de distinguer :

GEBROCHEN participe passé de GEBRECHEN
GEBROCHEN participe passé de BRECHEN
Il s'agit avant tout de générer des formes sans erreur et de les utiliser comme références.
L'étiquette AUXILIAIRE, REGULIER, IRREGULIER garantit la correction des découpages et plus tard, de la reconstruction du syntagme verbal.
L'étude du verbe n'étant pas l'objet de notre thèse, nous ne nous attarderons pas sur les différences et les similitudes des systèmes verbaux allemand, néerlandais...
Il nous a semblé que le classement proposé plus haut reflétait un dénominateur commun. Elaboré sur l'allemand, l'algorithme a fonctionné pour le néerlandais puis le luxembourgeois, sans subir de transformation, confirmant le bien-fondé de la technique utilisée (séparation des programmes et des données). Les spécificités de chaque langue sont en effet intégrées au niveau des fichiers.

4.3.2.2.3.3 Fichiers de racines

Les différents degrés d'achèvement des fichiers ci-après illustreront le rôle des données.
.VERBAL2, après la reconnaissance et le découpage éventuel de la partie préverbale, appréhende la racine par comparaison, en parcourant l'ensemble des racines régulières puis irrégulières. Le repérage seul ne nécessite qu'une liste simple des racines.
Exemple pour le luxembourgeois : MORPHLX(VERRG)

```
00010 0077
00020 0030
00030 6334
00040 APPER
00050 A*A*RD
00060 AKER
00070 A*IFER
00080 A*NNER
00090 A*NGSCHTEG
00100 A*NTWER
00110 BAALG
00120 BAU
00130 BAUPS
00140 BAASS
00150 BAATSCH
00160 BABBEL
00170 BALLER
00180 BASTEL
00190 BEAFLOSS
00200 BEDEN>G
00210 BENEID
00220 BEETSCH
00230 BEEN
00240 BEEZ
00250 BEDUPPS
00260 BEDUSEL
00270 BEDUX
00280 BEFRIDDEG
00290 BEGAACHEL
00300 BEGANN
00310 BEGE>IN
00320 BESICHT
00330 BETOUN
00340 BESCHA*FTEG
00350 BEWA*LTEG
00360 BEWEG
00370 BEWE*LLEG
00380 BEWIIRT
00390 BECHER
00400 BE>CHS
00410 BE>CK
00420 BEICHT
00430 BE>I
00440 BE>ISS
00450 BE*LZ
00460 BENGEL
00470 BE*SEL
00480 BESSER
00490 BIEDEL
00500 BIISCHT
00510 BLA*R
00520 BLECH
00530 BLIHNEL
00540 BLE*TZ
00550 BLIEDER
00560 BLUDD
00570 BOHNEL
00580 BOOTSCH
00590 BRADDEL
00600 BRAL
00610 BRATSCH
00620 BRAUCH
00630 BRE>I
00640 BRE*LL
00650 BRE*S
00660 BRUCK
00670 BRUED
00680 BUDDER
00690 BUDDEL
00700 BUER
00710 DAACH
00720 DABBER
00730 DAHH
00740 DANG
00750 DANZ
00760 DATZ
00770 DAUSCH
00780 DA*IT
00790 DA*IUEL
00800 DEEL
00810 DA*HNER
00820 DECK
00830 DE>ID
00840 DEIKSEL
00850 DIICHT
00860 DIEBEL
00870 DILL
00880 'DIHHER
00890 DRA*H
00900 DRA*NK
00910 DRE>CHEH
00920 DRECHSEL
00930 DRE>CK
00940 DRE>IW
00950 DRIIPS
00960 DRUDDEL
00970 DRUHH
00980 DUEBEL
00990 DUCK
01000 DUSCH
01010 DUZ
01020 EELI
```

```
Ø1Ø3Ø EECH
Ø1Ø4Ø E>IDERZ
Ø1Ø5Ø E>IER
Ø1Ø6Ø EIZ
Ø1Ø7Ø ERKLA*R
Ø1Ø8Ø ERNInn
Ø1Ø9Ø FAASCHT
Ø11ØØ FAASS
Ø111Ø FABEL
Ø112Ø FACKEL
Ø113Ø FAKEL
Ø114Ø FALZ
Ø115Ø FASCHT
Ø116Ø FASEL
Ø117Ø FATZ
Ø118Ø FAULZ
Ø119Ø FAUTEL
Ø12ØØ FAX
Ø121Ø FA*LSCH
Ø122Ø FA*NDEL
Ø123Ø FECHT
Ø124Ø FE>CK
Ø125Ø FEIER
Ø126Ø FEIL
Ø127Ø FE>IWER
Ø128Ø FEL
Ø129Ø FE*LL
Ø13ØØ FE*MM
Ø131Ø FE>NKEL
Ø132Ø FE*SCH
Ø133Ø FETT
Ø134Ø FE
Ø135Ø FIDDEL
Ø136Ø FIEDEH
Ø137Ø FIEDER
Ø138Ø FIERKEL
Ø139Ø FILL
Ø14ØØ FIMMEL
Ø141Ø FIIRn
Ø142Ø FISEL
Ø143Ø FISEH
Ø144Ø FLAATSCH
Ø145Ø FLACKER
Ø146Ø FLAH
Ø147Ø FLANTER
Ø148Ø FLAPP
Ø149Ø FLATSCH
Ø15ØØ FLATTER
Ø151Ø FLAUT
Ø152Ø FLA*T
Ø153Ø FLA*TSCH
Ø154Ø FLECHT
Ø155Ø FLECK
Ø156Ø FLE>CK
Ø157Ø FLEG
Ø158Ø FLE>IW
Ø159Ø FLERnZ
Ø16ØØ FLITSCH
Ø161Ø FLUCH
Ø162Ø FLUDDER
Ø163Ø FLUnn
Ø164Ø FLUPP
Ø165Ø FLUTSCH
Ø166Ø FOCHS
Ø167Ø FOCK
Ø168Ø FOLTER
Ø169Ø FONKEL
Ø17ØØ FODSCH
Ø171Ø FORn
Ø172Ø FRASCHT
Ø173Ø FRA*A*SCH
Ø174Ø FRA*CKS
Ø175Ø FRA*
Ø176Ø FRA*S
Ø177Ø FRE>CKEL
Ø178Ø FRECK
Ø179Ø FRIESS
Ø18ØØ FRIPP
Ø181Ø FRISEL
Ø182Ø FUCHTEL
Ø183Ø FUDDEL
Ø184Ø FUEBEL
Ø185Ø FUERDER
Ø186Ø FUERSCH
Ø187Ø FUnnEL
Ø188Ø FUSCH
Ø189Ø FUTTER
Ø19ØØ FUURZ
Ø191Ø FUUSS
Ø192Ø GAACKS
Ø193Ø GAAPS
Ø194Ø GABBER
Ø195Ø GAFEL
Ø196Ø GAMMZ
Ø197Ø GARREL
Ø198Ø GANNER
Ø199Ø GAUTSCH
Ø2ØØØ GA*A*SCHTER
Ø2Ø1Ø GA*IP
Ø2Ø2Ø GA*ISSEL
Ø2Ø3Ø GA*IZ
Ø2Ø4Ø GECKS
Ø2Ø5Ø GEI
Ø2Ø6Ø GIERKS
Ø2Ø7Ø GLADDER
Ø2Ø8Ø GLANN
Ø2Ø9Ø GLEW
Ø21ØØ GLE*NNER
Ø211Ø GLE*TZ
Ø212Ø GLE*TZER
Ø213Ø GUTZEL
Ø214Ø GRAATSCH
Ø215Ø GRAnGEL
Ø216Ø GRANZ
Ø217Ø GRAUL
Ø218Ø GRA*TSCH
Ø219Ø GRA*Z
Ø22ØØ GRE>ISS
Ø221Ø GREnZ
Ø222Ø GRIMMEL
Ø223Ø GRIPS
Ø224Ø GRÖnMEL
Ø225Ø GUERD
Ø226Ø HAASPEL
Ø227Ø HAASS
Ø228Ø HAnSTER
Ø229Ø HANDLAANGER
Ø23ØØ HAnDEL
Ø231Ø HANTE>IER
Ø232Ø HASEL
Ø233Ø HAUCH
Ø234Ø HAUL
Ø235Ø HAUS
Ø236Ø HAUSE>IER
Ø237Ø HAUW
Ø238Ø HA*A*SCH
Ø239Ø HA*ERD
Ø24ØØ HA*ERZ
Ø241Ø HA*FEL
Ø242Ø HA*MEL
Ø243Ø HA*NGEL
Ø244Ø HA*TSCHEL
Ø245Ø HE>IER
Ø246Ø HE>ISS
Ø247Ø HE>NKEL
Ø248Ø HETZ
Ø249Ø HICK
Ø25ØØ HIDD
Ø251Ø HIMMEL
Ø252Ø HOPS
Ø253Ø HUBBEL
Ø254Ø HOUTSCH
Ø255Ø HUCKEL
Ø256Ø HUMMER
Ø257Ø HUPP
Ø258Ø HUREL
Ø259Ø HUSCH
Ø26ØØ HUTSCHEL
Ø261Ø HUWWEL
Ø262Ø IDDERI
Ø263Ø IERDER
Ø264Ø IERW
Ø265Ø JABEL
Ø266Ø JACHTEL
Ø267Ø JADDER
Ø268Ø JAMER
Ø269Ø JAPP
Ø27ØØ JAPS
Ø271Ø JATSCHEL
Ø272Ø JE>InER
Ø273Ø JEKEL
Ø274Ø JHICK
Ø275Ø JHITZ
Ø276Ø JHUnn
Ø277Ø JHUPP
Ø278Ø JUCK
Ø279Ø JUPPEL
Ø28ØØ JUX
Ø281Ø KAALW
Ø282Ø KAASCHT
Ø283Ø KACH
Ø284Ø KALEnNER
Ø285Ø KALLEK
Ø286Ø KAPAUN
Ø287Ø KARSAATSCH
Ø288Ø KASSE>IER
Ø289Ø KATZ
Ø29ØØ KAUL
Ø291Ø KA*IL
Ø292Ø KA*IP
Ø293Ø KA*nn
Ø294Ø KA*PP
Ø295Ø KE<DDEL
Ø296Ø KE>IER
Ø297Ø KE>IP
Ø298Ø KEIn
Ø299Ø KELT
Ø3ØØØ KE*nNEG
Ø3Ø1Ø KE*PP
Ø3Ø2Ø KE*SS
Ø3Ø3Ø KICKEL
Ø3Ø4Ø KIERP
Ø3Ø5Ø KIERW
Ø3Ø6Ø KIERZ
Ø3Ø7Ø KILL
Ø3Ø8Ø KIPP
Ø3Ø9Ø KLAATSCH
```

03100 KLABBER
03110 KLAK
03120 KLAM
03130 KLAPP
03140 KLAU
03150 KLAUSCHTER
03160 KLA*G
03170 KLA*ER
03180 KLA*TSCH
03190 KLE>CK
03200 KLEMM
03210 KLENTSCH
03220 KLE*PPEL
03230 KLIBBER
03240 KLIEN
03250 KLIEW
03260 KLIMP
03270 KLOMP
03280 KLONK
03290 KLOTER
03300 KLUCKS
03310 KLUDDER
03320 KLUNTSCH
03330 KNABBEL
03340 KNABBER
03350 KNACK
03360 KNADDER
03370 KNAL
03380 KNASCHT
03390 KNA*TSCH
03400 KNAUSER
03410 KNAUTER
03420 KNAUTSCH
03430 KNA*IP
03440 KNA*PP
03450 KNA*TSCH
03460 KNA*TZEL
03470 KNE>CHEL
03480 KNE>CKS
03490 KNE>CK
03500 KNE>I
03510 KNIED
03520 KNIEWEL
03530 KNIEPS
03540 KNIWWEL
03550 KNONTER
03560 KNUBBEL
03570 KNUER
03580 KNUJHEL
03590 KNUPP
03600 KNUUTSCH
03610 KOL
03620 KOLL
03630 KOMPONE>IER
03640 KONTER
03650 KOPPEL
03660 KOSCHTER
03670 KONP
03680 KRAACH
03690 KRABBEL
03700 KRAID
03710 KRAUD
03720 KRAUSEL
03730 KRAZ
03740 KRA*CH
03750 KRA*LL
03760 KRA*MP
03770 KRE>CKEL
03780 KREGE>IL
03790 KRE>IN
03800 KREMPEL
03810 KREPE>IER
03820 KRE*SPEL
03830 KRIBBEL
03840 KROP
03850 KRIEWEL
03860 KUCK
03870 KUGEL
03880 KURE>IER
03890 KUSCHEL
03900 KUSCH
03910 KUTSCHE>IER
03920 KUUTSCH
03930 LAACH
03940 LABBER
03950 LABORE>IER
03960 LA*SCH
03970 LACK
03980 LAGER
03990 LAPP
04000 LA*A*SCHT
04010 LA*IT
04020 LA*NG
04030 LA*STER
04040 LE*FT
04050 LE>IER
04060 LEIER
04070 LE>IN
04080 LE>IS
04090 LE*MMEL
04100 LEESCHT
04110 LICH
04120 LIES
04130 LIEW
04140 LIICHT
04150 LIWISER
04160 LOMP
04170 LUEW
04180 LUUGER
04190 LUPP
04200 LUTSCH
04210 LUUSS
04220 MASSE>IER
04230 MAUER
04240 MAUFEL
04250 MAUL
04260 MAUSCHEL
04270 MAUTSCH
04280 MA*A*SCHTER
04290 MA*A*SSEL
04300 MA*ERDER
04310 ME*FF
04320 ME>IN
04330 MELD
04340 MELL
04350 MENG
04360 ME*NNER
04370 ME*NZ
04380 ME*SCH
04390 ME*SS
04400 METER
04410 MEIZEL
04420 MIDDEL
04430 MIERGEL
04440 MIERK
04450 MIERWEL
04460 MILLIOUN
04470 MIMM
04480 MINN
04490 MIPS
04500 MITT
04510 MIX
04520 MOL
04530 MOLTER
04540 MONP
04550 MONKEL
04560 MOOSS
04570 MOSCHTER
04580 MOTZ
04590 MONZ
04600 MUCKS
04610 MUERKS
04620 MULTIPLIZE>IER
04630 MUPP
04640 NABBEL
04650 NAPP
04660 NASCHEL
04670 NA*IP
04680 NE>CK
04690 NE>I
04700 NE>ITSCH
04710 NEL
04720 NE*SCHEL
04730 NETZ
04740 NIEWEL
04750 NOP
04760 NOTZ
04770 NUJHEL
04780 NUMERE>IER
04790 NUREL
04800 OFFRE>IER
04810 ORAKEL
04820 OUTN
04830 POCK
04840 PACHT
04850 PACK
04860 PAK
04870 PADDEL
04880 PAI
04890 PAKTE>IR
04900 PANZER
04910 PARK
04920 PASS
04930 PATSCH
04940 PAUER
04950 PAUS
04960 PAU
04970 PA*CKEL
04980 PA*IF
04990 PECH
05000 PEFFER
05010 PE*FFER
05020 PE>IL
05030 PELL
05040 PENDEL
05050 PE>NKEL
05060 PE>NK
05070 PENN
05080 PE*NSEL
05090 PE*SPER
05100 PICKE>IER
05110 PICK
05120 PIDDEL
05130 PIFF
05140 PIIPS
05150 PILGER
05160 PINSCH

```
05170 PIP
05180 PIPS
05190 PISACK
05200 PISS
05210 PLAATSCH
05220 PLACKE>IER
05230 PLAIN
05240 PLAK
05250 PLANG
05260 PLANZ
05270 PLAPPER
05280 LATZ
05290 PLA*TSCH
05300 PLA*TTEL
05310 PLE>CK
05320 PLE>ISCHTER
05330 PLE*NN
05340 PLE*NNER
05350 PLO
05360 PLOMP
05370 PLOOSCHTER
05380 PLOU
05390 PLOUF
05400 POLITIK
05410 POLSTER
05420 POMPEL
05430 POSTELE>IER
05440 POTER
05450 POUF
05460 PONKER
05470 PONZ
05480 PRAFF
05490 PRAKTIZE>IER
05500 PRAL
05510 PRA*ME>IER
05520 RE>IU
05530 PRESS
05540 PRIEDEG
05550 PROBE>IER
05560 PRODUZE>IER
05570 PROFEZEI
05580 PROJHEZE>IER
05590 PROST
05600 PROTZ
05610 PROUU
05620 PUDDEL
05630 PUDDER
05640 PUFF
05650 PULL
05660 PUNKTSCHWA*A*SS
05670 PUP
05680 PUSEL
05690 PUTSCH
05700 QUACKS
05710 QUAK
05720 QUATSCH
05730 QUELL
05740 QUE*LL
05750 QUE*TSCH
05760 QUIICKS
05770 QUIITSCH
05780 QUIK
05790 QUOKEL
05800 RAACH
05810 RABBEL
05820 RA*CHEL
05830 RACKER
05840 RAHH
05850 RAHONER
05860 RAHOSCHTER
05870 RAPP
05880 RASCHT
05890 RAS
05900 RAUH
05910 RAU
05920 RA*A*CH
05930 RA*A*CHER
05940 RA*CH
05950 RA*DEL
05960 RA*PS
05970 RA*Z
05980 RECHH
05990 REECH
06000 RE>CKEL
06010 RE*FFEL
06020 REGE>IER
06030 REGEL
06040 RE>IER
06050 REIH
06060 REN
06070 RE>NGEL
06080 RE>NG
06090 RE>NK
06100 RE*TSCH
06110 RETT
06120 RICH
06130 RICHT
06140 RIPP
06150 RÖMPEL
06160 ROTZ
06170 RUBBEL
06180 RUDDER
06190 RULL
06200 RUHH
06210 RUPP
06220 SABBEL
06230 SAIERZ
06240 SAK
06250 SALZ
06260 SAUH
06270 SAUS
06280 SA*A*CH
06290 SA*CH
06300 SA*CKEL
06310 SA*F
06320 SA*H
06330 SA*UEL
06340 SCHADDER
06350 SCHAFF
06360 SCHAF
06370 SCHAIH
06380 SCHALT
06390 SCHAL
06400 SCHANZ
06410 SCHAPP
06420 SCHARJEKEL
06430 SCHARWENZEL
06440 SCHAUER
06450 SCHAUTER
06460 SCHA*ERF
06470 SCHA*R
06480 SCHE>CK
06490 SCHEI
06500 SCHEKER
06510 SCHELL
06520 SCHE*LL
06530 SCHE>NG
06540 SCHE*FF
06550 SCHIERF
06560 SCHIFF
06570 SCHILI
06580 SCHIPF
06590 SCHIPG
06600 SCHLABBER
06610 SCHLADDER
06620 SCHLADDER
06630 SCHLAK
06640 SCHLAUTER
06650 SCHLAPP
06660 SCHLA*IN
06670 SCHLE>CK
06680 SCHLEIDER
06690 SCHLE>NGER
06700 SCHLENTER
06710 SCHLIBBER
06720 SCHLUECHT
06730 SCHLUPF
06740 SCHNAACH
06750 SCHNA*A*CHEL
06760 SCHNUDDEL
06770 SCHNADDER
06780 SCHNABBEL
06790 SCHNAUU
06800 SCHNECK
06810 SCHNEI
06820 SCHNE*TZEL
06830 SCHNOFFEL
06840 SCHNUDDEL
06850 SCHOCKS
06860 SCHOSSEL
06870 SCHOUN
06880 SCHRAUU
06890 SCHRE>CK
06900 SCRE>IPS
06910 SCHROMF
06920 SCHRUPP
06930 SCHUDDER
06940 SCHUED
06950 SCHUHH
06960 SCHUPP
06970 SCHWA*A*SS
06980 SCHNA*ERRZ
06990 SCHUEHH
07000 SCHUENK
07010 SE>CHER
07020 SEGEL
07030 SEI
07040 SE>IN
07050 SE*NNES
07060 SEN
07070 SENK
07080 SE*NNER
07090 SICH
07100 SIFF
07110 SUHH
07120 SOUER
07130 SPAASS
07140 SPAGEE>IR
07150 SPAN
07160 SPE*CHE>IR
07170 SPE>IN
07180 SPELL
07190 SPIEEL
07200 SPILL
07210 SPIGNE>IER
07220 SPLA*ITER
07230 SPLE>CK
```

07240 SPRA*D
07250 SPRENG
07260 SPUER
07270 SPULL
07280 STACK
07290 STAH
07300 STA*
07310 STA*ERK
07320 STA*IP
07330 STE*BS
07340 STE*TZ
07350 STE>CHEL
07360 STE>CKEL
07370 STE>CK
07380 STE>IER
07390 STEIER
07400 STE*LL
07410 STE*LP
07420 STE*MM
07430 STEMM
07440 STEMPEL
07450 STE*PPEL
07460 STEPP
07470 STIERM
07480 STODE>IR
07490 STOLPER
07500 STOLSE>IR
07510 STOPP
07520 STRAPP
07530 STRA*
07540 STRA*IF
07550 STRE>CK
07560 STRECK
07570 STREMM
07580 STRENZ
07590 STRE*PP
07600 STRE*TZ
07610 STRIEM
07620 STROF
07630 STROMPEL
07640 STROTZ
07650 STRUEMEL
07660 STRUMM
07670 STRUCKEL
07680 STUCK
07690 STUTZ
07700 SUCKEL
07710 SUDDEL
07720 SUERG
07730 TAASCHT
07740 TA*SSEL
07750 TE>CK
07760 TE>ITSCH
07770 TE*LTER
07780 TIERKEL
07790 TIERM
07800 TOMMEL
07810 TOMP
07820 TOUF
07830 TOZ
07840 TRAATSCH
07850 TRAPP
07860 TRAUER
07870 TRAUFEL
07880 TRE*MMEL
07890 TRE*NDEL
07900 TRE*PPEL
07910 TRE*TZ
07920 TRICHTER
07930 TRIMM
07940 TRIWWEL
07950 TROMM
07960 TROT
07970 TROTZ
07980 TROUM
07990 TRUDDEL
08000 TRUTSCH
08010 TUCK
08020 TUDDEL
08030 TUPP
08040 TUSCHEL
08050 TUT
08060 UECHT
08070 UERTEL
08080 UZ
08090 U*B
08100 WAACH
08110 WAARD
08120 WABBEL
08130 WACKEL
08140 WALZ
08150 WANDEL
08160 WANN
08170 WATSCHEL
08180 WA*A*CH
08190 WA*D
08200 WA*NZEL
08210 WE>CKEL
08220 WE>ITSCH
08230 WE*LZ
08240 WE>NK
08250 WENN

.MORPHLX(VERBIR) contient les racines irrégulières :

```
Ø1116 GANK
Ø1129 GEE
Ø1139 GE*
Ø1149 GI
Ø1159 GE>NG
Ø1169 GONG
Ø1179 GOUNG
Ø1189 GUNG
Ø1199 GAANG
Ø1209 GE>IF
Ø1219 GE>I
Ø1229 GE>ING
Ø1239 GIA*
Ø1249 GOUF
Ø1259 GOUW
Ø1269 GO
Ø1279 GE>IF
Ø1289 GEROD
Ø1296 GERIK
Ø1309 GERUCH
Ø1319 GESA*I
Ø1329 GESI
Ø1339 GESOUCH
Ø1349 GESE>ICH
Ø1359 GESE>NG
Ø1369 GESCHE>ICH
Ø1379 GESCHE>I
Ø1389 GESCHIT
Ø1399 GESCHI
Ø1409 GESCHUCH
Ø1419 GRAIF
Ø1429 GRAFF
Ø1439 GRUEF
Ø1449 GRUEW
Ø1459 GRUF
Ø1469 HAE
Ø1479 HUCH
Ø1489 HAL
Ø1499 HA*L
Ø1509 HA*T
Ø1519 HOUL
Ø1529 HE>IL
Ø1539 HAAL
Ø1549 HE>IER
Ø1559 HOUER
Ø1569 HA*NK
Ø1579 HA
Ø1589 HIEF
Ø1599 HOUNG
Ø1609 HONG
Ø1619 HE>ING
Ø1629 HE>NG
Ø1639 HE*LLEF
Ø1649 HELLEF
Ø1659 HULLEF
Ø1669 HOLLEF
Ø1679 HUEL
Ø1689 HUE
Ø1699 HU
Ø1709 HE*LL
Ø1719 HU
Ø1729 HE*L
Ø1739 HOLL
Ø1749 HIDD
Ø1759 HIT
Ø1769 HUTT
Ø1779 IERW
Ø1789 IERF
Ø1799 IESS
Ø1809 IE*SCH
Ø1819 IE*S
Ø1829 E*SCH
Ø1839 E*S
Ø1849 GIESS
Ø1859 JA*IZ
Ø1869 JAUT
Ø1879 KAAF
Ø1889 KAF
Ø1899 KEEF
Ø1909 KE>IF
Ø1919 KE*NN
Ø1929 KANN
Ø1939 KENN
Ø1949 KASCH
Ø1959 KA
Ø1969 KONN
Ø1979 KONN
Ø1989 KOUH
Ø1999 KE>IN
Ø2009 KLANN
Ø2019 KLE*NN
Ø2029 KLONN
Ø2039 KLED
Ø2049 KLEET
Ø2059 KRA*ISCH
Ø2069 KRASCH
Ø2079 KRE>IE
Ø2089 KRIT
Ø2096 KRIS
Ø2109 KRUG
Ø2119 KRUT
Ø2129 KRE>IG
Ø2139 KRICH
Ø2149 KRIK
Ø2159 LAF
Ø2169 LOF
Ø2179 LUF
Ø2189 LEEF
Ø2199 LEI
Ø2209 LA*IT
Ø2219 LE
Ø2229 LOUG
Ø2239 LE>IG
Ø2249 LE>I
Ø2259 LIT
Ø2269 LUNN
Ø2279 LUGG
Ø2289 LUJ
Ø2299 LIEW
Ø2309 LIEF
Ø2319 LOSS
Ø2329 LUSS
Ø2339 LE>ISS
Ø2349 MAACH
Ø2359 MA
Ø2369 ME>ICH
Ø2379 ME>CH
Ø2389 MUSS
Ø2399 MISS
Ø2409 NENN
Ø2419 NANN
Ø2429 NETZ
Ø2439 NAT
Ø2449 PA*IF
Ø2459 PAFF
Ø2469 RE>IER
Ø2479 ROLER
Ø2489 RUFF
Ø2499 RIFF
Ø2509 RICH
Ø2519 ROCH
Ø2529 SANG
Ø2539 SAUF
Ø2549 SA*IF
Ø2559 SOFF
Ø2569 SCHA*ISS
Ø2579 SCHASS
Ø2589 SCHA*TZ
Ø2599 SCHAT
Ø2609 SCHE*ZZ
Ø2619 SCHIDD
Ø2629 SCHOTT
Ø2639 SCHUTT
Ø2649 SCHE>ISS
Ø2659 SCHOSS
Ø2669 SCHE>ING
Ø2679 SCHE>NG
Ø2689 SCHE*NN
Ø2699 SCHANN
Ø2709 SCHAAF
Ø2719 SCHAFF
Ø2729 SCHAF
Ø2739 SCHLA*ICH
Ø2749 SCHLACH
Ø2759 SCHLA*IF
```

```
02760 SCHLAFF
02770 SCHLEEF
02780 SCHLEF
02790 SCHLOF
02800 SCHLE>IF
02810 SCHLO
02820 SCHNE*LI
02830 SCHNALT
02840 SCHNOLT
02850 SCHNOLZ
02860 SCHNOULT
02870 SCHNA*IZ
02880 SCHNAUT
02890 SCHNEID
02900 SCHNUT
02910 SCHNIDO
02920 SCHNE>I
02930 SCHNEI
02940 SCHNECH
02950 SCHNEK
02960 SCHREIW
02970 SCHRIWW
02980 SCHRUF
02990 SCHREIF
03000 SCHRIFF
03010 SCHRIF
03020 SCHWIER
03030 SCHWUER
03040 SCHWA*IZ
03050 SCHWAT
03060 SE*IZ
03070 SE>IZ
03080 SOUZ
03090 SIESS
03100 SIEW
03110 SETZ
03120 SAT
03130 SOLL
03140 SOT
03150 SO
03160 SEE
03170 SIE
03180 SPA*IZ
03190 SPAU
03200 SPANN
03210 SPONN
03220 SPA*R
03230 SPAAR
03240 SPIER
03250 SPUER
03260 SPRANG
03270 SPRE>NG
03280 STIECH
03290 STOUCH
03300 STACH
03310 STE>ICH
03320 STIEL
03330 STUEL
03340 STIERW
03350 STUERW
03360 STIERZ
03370 STUERT
03380 STO
03390 STI
03400 STEE .
03410 STELL
03420 STALL
03430 STOUNG
03440 STONG
03450 STE>ING
03460 STE>NG
03470 STE>I
03480 STAND
03490 STAN
03500 STOUSS
03510 STE>ISS
03520 STRA*ICH
03530 STRACH
03540 TAUSCH
03550 TOSCH
03560 TREFF
03570 TRAFF
03580 TRIED
03590 TRE*T
03600 TRUED
03610 TRATT
03620 VERGIES
03630 VERGLA*ICH
03640 VERGLACH
03650 VERLE>IER
03660 VERLUER
03670 VERSPRIECH
03680 VERSPRACH
03690 VERUERTE*L
03700 VERUERTEL
03710 WAR
03720 WA*R
03730 WA*ERD
03740 WIER
03750 WIESCH
03760 WA*ER
03770 WER
03780 WOLL
03790 WE>IL
03800 WE*LL
03810 WE*SS
03820 WEESS
03830 WOUSS
03840 WOSS
03850 WE>ISS
03860 WOR
03870 WOSCH
03880 WUESS
03890 WIISS
03900 ZE>I
03910 ZUCH
03920 ZUNN
03930 ZEI
03940 ZE
```

Pour le néerlandais, on résout simplement le problème que posent quelques règles orthographiques :
- Lorsqu'un mot contenant une voyelle impure (dans une syllabe fermée) prend une terminaison (-e, -en...), on redouble dans l'écriture la consonne qui suit la voyelle impure.
- Les voyelles pures **a, e, o** et **u** sont simples dans une syllabe ouverte et géminées dans une syllabe fermée.
- les sourdes se transforment en sonores (assimilation) à l'intérieur ou à la fin d'une syllabe et s'écrivent :

v --> f
z --> s

S'il est possible de calculer les formes à partir de quelques règles et d'une dizaine d'instructions, il est beaucoup plus pratique et rapide d'en tenir compte dans la présentation des données. C'est ainsi que figurent dans .MORPHOL(VERBRG) :

ØØ31Ø	BEVATT	et	ØØ32Ø	BEVAT	de BEVATTEN contenir
ØØ24Ø	BEGROT	et	ØØ23Ø	BEGRODT	de BEGROTEN évaluer
Ø114Ø	DRAV	et	Ø113Ø	DRAAF	de DRAVEN trotter
Ø181Ø	GRAZ	et	Ø182Ø	GRAAS	de GRAZEN brouter

La lecture de ces fichiers par variables basées est extrêmement rapide. On peut donc rentrer toutes les variantes, ce qui donne d'autres possibilités, dans le cas des verbes irréguliers notamment, pour lesquels la modification du radical n'est pas toujours uniforme. Ceci permet de différencier quelques formes, grâce à l'adjonction d'un code dans le fichier .MORPHOL(VERBIR) :

Ø144Ø ØHANG Ø --> pas de différenciation, le radical HANG se retrouvant au participe passé de HANGEN pendre.

Ø141Ø *GRIJP * --> radical à l'infinitif et à l'indicatif présent (GREEP à l'imparfait, GEGREPEN au participe passé) de GRIPSEN saisir

Ø414Ø STORV radical au participe passé (STERV infinitif, indicatif présent et STIERF imparfait) de STERVEN, mourir

.MORPHOL(VERBRG) :

```
Ø1669 GIECHEL
Ø1679 GILL
Ø1689 GIL
Ø1699 GISS
Ø1709 GIS
Ø1719 GLANZ
Ø1729 GLIPP
Ø1739 GLIP
Ø1749 GLOEI
Ø1759 GLUUR
Ø1769 GLUR
Ø1779 GOOI
Ø1789 GLOF
Ø1799 GOLV
Ø1809 GRAAI
Ø1819 GRAZ
Ø1829 GRAAS
Ø1839 GRIJNZ
Ø1849 GRINNIK
Ø1859 GRIPP
Ø1869 GRIP
Ø1879 GROEI
Ø1889 GROET
Ø1899 GROHH
Ø1909 GROH
Ø1919 GROND
Ø1929 GUNN
Ø1939 GUN
Ø1949 HAAST
Ø1959 HAKK
Ø1969 HAK
Ø1979 HAAL
Ø1989 HAL
Ø1999 HANDEL
Ø2ØØØ HANDHAAF
Ø2Ø1Ø HANDHAV
Ø2Ø2Ø HANDIG
Ø2Ø3Ø HARTIG
Ø2Ø4Ø HANTEER
Ø2Ø5Ø HANTER
Ø2Ø6Ø HAND
Ø2Ø7Ø HAAT
Ø2Ø8Ø HAT
Ø2Ø9Ø HECHT
Ø21ØØ HELDER
Ø211Ø HELS
Ø212Ø HEERS
Ø213Ø HEUG
Ø214Ø HIJG
Ø215Ø HINDER
Ø216Ø HINK
Ø217Ø HITS
Ø218Ø HOED
Ø219Ø HOEV
Ø22ØØ HOOG
```

02210 HOG
02220 HOLL
02230 HOL
02240 HOON
02250 HON
02260 HOOI
02270 HOOP
02280 HOP
02290 HOOR
02300 HOR
02310 HUIL
02320 HUIVER
02330 HUIZ
02340 HUIS
02350 HUNKER
02360 HURK
02370 HUUR
02380 HUR
02390 HUTS
02400 INNER
02410 IJSBEER
02420 IJSBER
02430 JANK
02440 JENK
02450 JOKK
02460 JOK
02470 JUICH
02480 KAARST
02490 KAATS
02500 KAKK
02510 KAK
02520 KAMP
02530 KAPP
02540 KAP
02550 KLEDER
02560 KLEMTOON
02570 KLEMTON
02580 KENN
02590 KEN
02600 KEER
02610 KER
02620 KLAAG
02630 KLAG
02640 KLAPP
02650 KLAP
02660 KEUR
02670 KLAAR
02680 KLAR
02690 KLEED
02700 KLED
02710 KLEMM
02720 KLEM
02730 KLEER
02740 KLER
02750 KLEEF

02760 KLEV
02770 KLOPP
02780 KLOP
02790 KNAPP
02800 KNAP
02810 KNALL
02820 KNAL
02830 KNIKK
02840 KNIK
02850 KNIEL
02860 KNIPPER
02870 KNIPP
02880 KNIP
02890 KNOEI
02900 KNOOP
02910 KNOP
02920 KOESTER
02930 KOOK
02940 KOK
02950 KOMMER
02960 KONDIG
02970 KOPPEL
02980 KOSTIG
02990 KOST
03000 KRABBEL
03010 KRABB
03020 KRAAK
03030 KRAK
03040 KREUN
03050 KRASS
03060 KRAS
03070 KRIJS
03080 KRONKEL
03090 KROON
03100 KRON
03110 KUCH
03120 KWAAK
03130 KWAKK
03140 KWAK
03150 KWEEK
03160 KWEKK
03170 KWEL
03180 KWETS
03190 LAAG
03200 LAG
03210 LAKK
03220 LAK
03230 LAMM
03240 LAM
03250 LAST
03260 LAZER
03270 LEDIG
03280 LEEG
03290 LEGG
03300 LEG

03310 LEEN
03320 LEN
03330 LEER
03340 LER
03350 LETT
03360 LET
03370 LEUR
03380 LEID
03390 LEMMER
03400 LENG
03410 LEUN
03420 LEVER
03430 LEEF
03440 LEV
03450 LIJM
03460 LIJN
03470 LIKK
03480 LIK
03490 LIEV
03500 LOEI
03510 LOER
03520 LOKK
03530 LOK
03540 LON
03550 LOON
03560 LOSS
03570 LOS
03580 LOOS
03590 LOZ
03600 LOV
03610 LOOF
03620 LUID
03630 LUISTER
03640 LUKK
03650 LUK
03660 MAAI
03670 MACHTIG
03680 MAAK
03690 MAK
03700 MANN
03710 MAN
03720 MARTEL
03730 MATIG
03740 MEERDER
03750 MELD
03760 MELK
03770 MEEM
03780 MENG
03790 MEN
03800 MERK
03810 MIKK
03820 MIK
03830 MINK
03840 MINN
03850 MIN

03860 MISS
03870 MIS
03880 MOEDIG
03890 MOED
03900 MOEI
03910 MOMPEL
03920 MOORD
03930 MORREL
03940 MURMEL
03950 NADER
03960 NAAK
03970 NAK
03980 NAUW
03990 NEDER
04000 NEGER
04010 NEIG
04020 NESTEL
04030 NIETIG
04040 NIEUW
04050 NIEZ
04060 NIES
04070 NOEM
04080 NUTT
04090 NUT
04100 OEFEN
04110 OFFER
04120 OOGST
04130 OOG
04140 OG
04150 OPPER
04160 OPEN
04170 ORDEN
04180 PAKK
04190 PAK
04200 PAL
04210 PASSER
04220 PAR
04230 PASS
04240 PAS
04250 PEINZ
04260 PIRK
04270 PLAATS
04280 PRAAT
04290 PROEF
04300 PRAT
04310 PROEV
04320 PEUTER
04330 PIEKER
04340 PIKK
04350 PIK
04360 PLAAG
04370 PLAG
04380 PLAKK
04390 PLAK
04400 PLANN
04410 PLAN
04420 PLANT
04430 PLEIT
04440 PLICHT
04450 PLOFF
04460 PLOF
04470 PLOOI
04480 POETS
04490 PLUKK
04500 PLUK
04510 POOG
04520 POG
04530 POLIJST
04540 POLS
04550 POMP
04560 PRAAT
04570 PRAT
04580 PREK
04590 PREEK
04600 PRENT
04610 PRESTER
04620 PRIJZ
04630 PRIJS
04640 PRIKKEL
04650 PRIKK
04660 PRIK
04670 PROBEER
04680 PROBER
04690 PROEF
04700 PROEV
04710 PUTT
04720 PUT
04730 RAD
04740 RASP
04750 RASS
04760 RAS
04770 RAAS
04780 RAZ
04790 RAK
04800 RAAK
04810 RAMMEL
04820 RECHT
04830 REDD
04840 REDENER
04850 REDENEER
04860 RED
04870 REGEL
04880 REGEN
04890 REGER
04900 REID
04910 REIK
04920 REINIG
04930 REIZ
04940 REIS
04950 REKEN
04960 REKK
04970 REK
04980 REMM
04990 REM
05000 RENN
05010 REN
05020 REPP
05030 REP
05040 RICHT
05050 RILL
05060 RIL
05070 RING
05080 RITSEL
05090 ROEI
05100 ROER
05110 RUST
05120 ROER
05130 ROOK
05140 ROK
05150 ROLL
05160 ROL
05170 ROMMEL
05180 ROMPEL
05190 ROTT
05200 ROT
05210 ROUW
05220 ROV
05230 ROOF
05240 RUCHT
05250 RUIL
05260 RUIM
05270 RUIS
05280 RUKK
05290 RUK
05300 RUST
05310 SCHAATS
05320 SCHADIG
05330 SCHAAD
05340 SCHAD
05350 SCHAFF
05360 SCHAF
05370 SCHAKEL
05380 SCHAKER
05390 SCHAKEER
05400 SCHAAK
05410 SCHAAM
05420 SCHAK
05430 SCHAM
05440 SCHARREL
05450 SCHATT
05460 SCHAT
05470 SCHAAF
05480 SCHAV
05490 SCHEID
05500 SCHREEL

05510 SCHEL
05520 SCHERn
05530 SCHERP
05540 SCHETS
05550 SCHEUR
05560 SCHIED
05570 SCHIKK
05580 SCHIK
05590 SCHILDER
05600 SCHILL
05610 SCHIL
05620 SCHIMP
05630 SCHITTER
05640 SCHOBB
05650 SCHOB
05660 SCHOEI
05670 SCHOKK
05680 SCHOK
05690 SCHOMMEL
05700 SCHOPP
05710 SCHOP
05720 SCHORS
05730 SCHORREL
05740 SCHOTEL
05750 SCHRAG
05760 SCHRAAG
05770 SCHRAAL
05780 SCHRAL
05790 SCHRAMM
05800 SCHRAM
05810 SCHRANK
05820 SCHRAPP
05830 SCHRAP
05840 SCHREEUW
05850 SCHREI
05860 SCHROEF
05870 SCHROF
05880 SCHROL
05890 SCHROOL
05900 SCHROMPEL
05910 SCHOUW
05920 SCHROOI
05930 SCHUDD
05940 SCHUD
05950 SCHUIER
05960 SCHUIFEL
05970 SCHUIn
05980 SCHUIN
05990 SCHULDIG
06000 SCHULD
06010 SCHULP
06020 SCHUR
06030 SCHUUR
06040 SCHUTTER
06050 SCHUTT
06060 SCHUT
06070 SCHUUW
06080 SEFF
06090 SEF
06100 SEIN
06110 SEIZ
06120 SEIS
06130 SIER
06140 SISS
06150 SIS
06160 SJOUW
06170 SKI
06180 SLAAG
06190 SLAG
06200 SLAAF
06210 SLAV
06220 SLENTER
06230 SLEEP
06240 SLEP
06250 SLIKK
06260 SLIK
06270 SLINGER
06280 SLISS
06290 SLIS
06300 SLOMMER
06310 SLOP
06320 SLOOP
06330 SLOOF
06340 SLOV
06350 SLUIMER
06360 SMAKK
06370 SMAK
06380 SMAAL
06390 SMAL
06400 SMED
06410 SMEED
06420 SMEK
06430 SMEEK
06440 SMETT
06450 SMET
06460 SMOR
06470 SMOCR
06480 SNAPP
06490 SNAP
06500 SNAUW
06510 SNELL
06520 SNEL
06530 SNEEUW
06540 SNIKK
06550 SNIK
06560 SNOER
06570 SNUFFEL
06580 SOMn
06590 SOn
06600 SPANN
06610 SPAN
06620 SPAR
06630 SPAAR
06640 SPATT
06650 SPAT
06660 SPELL
06670 SPEEL
06680 SPEL
06690 SPEUR
06700 SPIED
06710 SPIEGEL
06720 SPIES
06730 SPLITS
06740 SPOEL
06750 SPOTT
06760 SPOT
06770 SPREID
06780 SPUI
06790 STAK
06800 STAAK
06810 STAMM
06820 STAM
06830 STAPEL
06840 STAPP
06850 STAP
06860 STAAR
06870 START
06880 STAR
06890 STED
06900 STEED
06910 STELL
06920 STEL
06930 STAMM
06940 STAN
06950 STAND
06960 STILL
06970 STIL
06980 STEMPEL
06990 STERK
07000 STICHT
07010 STIKK
07020 STIK
07030 STILER
07040 STILEER
07050 STIPPEL
07060 STOK
07070 STOOK
07080 STOT
07090 STOOT
07100 STOPP
07110 STOP
07120 STORn
07130 STOOR
07140 STORn
07150 STOR

07160 STRAFF
07170 STRAF
07180 STRAL
07190 STRAAL
07200 STRAND
07210 STREKK
07220 STREK
07230 STREEL
07240 STREEP
07250 STREL
07260 STREP
07270 STREEF
07280 STREV
07290 STROOI
07300 STROOM
07310 STROM
07320 STRUIKEL
07330 STUIT
07340 STUIV
07350 STUIF
07360 STUUR
07370 STUR
07380 SUKKEL
07390 TAL
07400 TAAL
07410 TAPP
07420 TAP
07430 TAST
07440 TEKEN
07450 TEISTER
07460 TELL
07470 TEL
07480 TER
07490 TEER
07500 TIER
07510 TIKK
07520 TIK
07530 TILL
07540 TIL
07550 TINNER
07560 TINTEL
07570 TOG
07580 TOOG
07590 TOETS
07600 TOM
07610 TOOM
07620 TOOI
07630 TOON
07640 TON
07650 TRACTEER
07660 TRACTER
07670 TRAIN
07680 TRAPP
07690 TRACHT
07700 TRAP
07710 TRILL
07720 TRIL
07730 TREUR
07740 TROOST
07750 TROUW
07760 TUIG
07770 TWIJFEL
07780 TWIST
07790 UITNODIG
07800 VAARDIG
07810 VATT
07820 VAT
07830 VEILIG
07840 VELL
07850 VEL
07860 VERANDER
07870 VERDICHT
07880 VERBEELD
07890 VERBETER
07900 VERDOMM
07910 VERDOM
07920 VERGROOT
07930 VERGROT
07940 VERKLEINER
07950 VERMINDER
07960 VERV
07970 VEERF
07980 VELD
07990 VESTIG
08000 VIER
08010 VLOED
08020 VLOEI
08030 VLOEK
08040 VLUCHT
08050 VOEG
08060 VOEL
08070 VOER
08080 VOETBALL
08090 VOLG
08100 VORDER
08110 VORM
08120 VOUW
08130 VREDIG
08140 VREEMD
08150 VREZ
08160 VREES
08170 VRUCHT
08180 VULL
08190 VUL
08200 VAST
08210 WAAI
08220 WAARDER
08230 WAARDEER
08240 WAARDIG
08250 WACHT
08260 WAG
08270 WAAG
08280 WAK
08290 WANDEL
08300 WANKEL
08310 WAPEN
08320 WAPPER
08330 WARM
08340 WAST
08350 WEDD
08360 WED
08370 WEG
08380 WEES
08390 WEIGER
08400 WEKK
08410 WEK
08420 WELDIG
08430 WEND
08440 WENK
08450 WENN
08460 WENS
08470 WEN
08480 WERK
08490 WEZENLIJK
08500 WIJD
08510 WIJL
08520 WIJZIG
08530 WIKKEL
08540 WINKEL
08550 WINTER
08560 WIPP
08570 WIP
08580 WISSEL
08590 WISS
08600 WIS
08610 WITTIG
08620 WOED
08630 WOEK
08640 WOEST
08650 WONDER
08660 WOND
08670 WON
08680 WOON
08690 WOORDIG
08700 WORSTEL
08710 WORTEL
08720 WREK
08730 WUIV
08740 WUIF
08750 ZAAI
08760 ZAAG
08770 ZAG
08780 ZAKK
08790 ZAK
08800 ZEGEN

```
00810 ZEIL
00820 ZETT
00830 ZET
00840 ZEUR
00850 ZIEL
00860 ZINN
00870 ZIN
00880 ZOEN
00890 ZORG
00900 ZUCHT
00910 ZUIN
00920 ZUIVER
00930 ZWAAI
00940 ZWEEF
00950 ZWEV
00960 ZWEEL
00970 ZWEL
00980 ZWEEP
00990 ZWEP
01000 ZWETS
01010 ZWEET
01020 ZWET
01030 ZWEV
```

MORPHOL(VERBIR) :

```
01660 ØHIEUU
01670 ØJAAG
01680 ØJAG
01690 ØJOEG
01700 ØKERV
01710 ØKERF
01720 ØKORF
01730 ØKORV
01740 *KIEZ
01750 ØKIES
01760 ØKOOS
01770 ØKOZ
01780 *KIJK
01790 ØKEEK
01800 ØKEK
01810 ØKIJV
01820 ØKIJF
01830 ØKEEF
01840 ØKEV
01850 *KLINN
01860 ØKLIN
01870 ØKLONN
01880 ØKLON
01890 *KLINK
01900 ØKLONK
01910 *KNIJP
01920 ØKNEEP
01930 ØKNEP
01940 ØKON
01950 ØKUAM
01960 ØKOOP
01970 *KOP
01980 ØKOCH
01990 *KRIJG
02000 ØKREEG
02010 ØKREG
02020 *KRIJT
02030 ØKREET
02040 ØKRET
02050 *KRIMP
02060 ØKROMP
02070 *KRUIP
02080 ØKROOP
02090 ØKROP
02100 ØKUNN
02110 ØKUN
02120 ØKAN
02130 ØKON
02140 ØLACH
02150 ØLAAD
02160 ØLAD
02170 ØLAAT
02180 ØLAT
02190 ØLIET
02200 ØLEES
02210 ØLEZ
02220 ØLAZ
02230 ØLAS
02240 *LIEG
02250 ØLOOG
02260 ØLOG
02270 *LIGG
02280 ØLIG
02290 ØLAG
02300 ØLEG
02310 *LIJD
02320 ØLEED
02330 ØLED
02340 *LIJK
02350 ØLEEK
02360 ØLEK
02370 ØLOOP
02380 ØLOP
02390 ØLIEP
02400 ØMELK
02410 ØMOLK
02420 ØMEET
02430 ØMET
02440 ØMAT
02450 *MIJD
02460 ØMEED
02470 ØMED
02480 ØMOET
02490 ØMOES
02500 ØMOOG
02510 ØMOG
02520 ØMAG
02530 ØMOCH
02540 ØMEEM
02550 ØMEM
02560 ØMAM
02570 ØMOM
02580 ØMIJG
02590 ØMEEG
02600 ØMEG
02610 *MIJP
02620 ØMEEP
02630 ØMEP
02640 ØONTGINN
02650 ØONTGIN
02660 ØONTGONN
02670 ØONTGON
02680 ØONTLUIK
02690 ØONTLOOK
02700 ØONTLOK
02710 ØPLEEG
02720 *PLEG
02730 ØPLACH
02740 ØPLUIZ
02750 ØPLUIS
```

```
02760 ØPLOOS
02770 ØPLOZ
02780 *PRIJZ
02790 ØPRIJS
02800 ØPREES
02810 ØPREZ
02820 ØRAAD
02830 ØRAD
02840 ØRIED
02850 ØRIEK
02860 *RUIK
02870 ØROOK
02880 ØROK
02890 *RIJD
02900 ØREED
02910 ØRED
02920 ØRIJZ
02930 ØRIJS
02940 ØREES
02950 ØREZ
02960 ØROEP
02970 ØRIEP
02980 ØSCHEID
02990 *SCHELD
03000 ØSCHOLD
03010 ØSCHEND
03020 ØSCHOND
03030 *SCHENK
03040 ØSCHONK
03050 *SCHEPP
03060 *SCHEP
03070 ØSCHIEP
03080 ØSCHAP
03090 ØSCHEER
03100 *SCHER
03110 ØSCHOOR
03120 ØSCHOR
03130 *SCHIET
03140 ØSCHOOT
03150 ØSCHOT
03160 *SCHIJN
03170 ØSCHEEN
03180 ØSCHEN
03190 *SCHRIJD
03200 ØSCHREED
03210 ØSCHRED
03220 *SCHRIJF
03230 *SCHRIJV
03240 ØSCHREEF
03250 ØSCHREV
03260 *SCHRIKK
03270 *SCHRIK
03280 ØSCHROKK
03290 ØSCHROK
03300 ØSCHUIL
03310 ØSCHOOL
03320 ØSCHOL
03330 ØSCHUIF
03340 *SCHUIV
03350 ØSCHOOF
03360 ØSCHOV
03370 ØSLAA
03380 ØSLA
03390 ØSLOEG
03400 ØSLAAP
03410 ØSLAP
03420 ØSLIEP
03430 ØSLIJP
03440 ØSLEEP
03450 ØSLEP
03460 *SLIJT
03470 ØSLEET
03480 ØSLET
03490 ØSLINK
03500 ØSLONK
03510 *SLUIP
03520 ØSLOOP
03530 ØSLOP
03540 *SLUIT
03550 ØSLOOT
03560 ØSLOT
03570 *SMELT
03580 ØSMOLT
03590 *SMIJT
03600 ØSMEET
03610 ØSMET
03620 *SNIJD
03630 ØSNEED
03640 ØSNED
03650 ØSNUIT
03660 ØSNOOT
03670 ØSNOT
03680 ØSNUIF
03690 *SNUIV
03700 ØSNOOF
03710 ØSNOV
03720 ØSPANN
03730 ØSPAN
03740 *SPIJT
03750 ØSPEET
03760 ØSPET
03770 ØSPINN
03780 ØSPIN
03790 ØSPONN
03800 ØSPON
03810 *SPLIJT
03820 ØSPLEET
03830 ØSPLET
03840 *SPREEK
03850 *SPREK
03860 ØSPRAK
03870 ØSPROK
03880 *SPRING
03890 ØSPRONG
03900 ØSPRUIT
03910 ØSPROOT
03920 ØSPROT
03930 ØSPUG
03940 ØSPOOG
03950 ØSPOG
03960 *SPUIT
03970 ØSPOOT
03980 ØSPOT
03990 ØSTAA
04000 ØSTA
04010 ØSTOND
04020 *STEEK
04030 *STEK
04040 ØSTAK
04050 ØSTOK
04060 *STEEL
04070 *STEL
04080 ØSTAL
04090 ØSTOL
04100 *STEERF
04110 *STERV
04120 ØSTIERF
04130 ØSTIERV
04140 ØSTORV
04150 *STIJF
04160 *STIJV
04170 ØSTEEF
04180 ØSTEV
04190 ØSTIJG
04200 ØSTEEG
04210 ØSTEG
04220 ØSTINK
04230 ØSTONK
04240 ØSTOOT
04250 ØSTOT
04260 ØSTIET
04270 *STRIJD
04280 ØSTREED
04290 ØSTRED
04300 *STRIJK
04310 ØSTREEK
04320 ØSTREK
04330 *STUIF
04340 *STUIV
04350 ØSTOOF
04360 ØSTOV
04370 ØTIJG
04380 ØTOOG
04390 ØTOG
04400 ØTREED
```

```
04410 ØTRAD
04420 ØTRED
04430 *TREFF
04440 *TREF
04450 ØTROFF
04460 ØTROF
04470 *TREKK
04480 *TREK
04490 ØTROKK
04500 ØTROK
04510 ØVALL
04520 ØVAL
04530 ØVIEL
04540 ØVANG
04550 ØVING
04560 ØVAAR
04570 ØVAR
04580 ØVOER
04590 *VECHT
04600 ØVOCHT
04610 *VERDRIET
04620 ØVERDROOT
04630 ØVERDROT
04640 *VERDUIJN
04650 ØVERDWEEN
04660 ØVERDWEN
04670 ØVERGEET
04680 ØVERGET
04690 ØVERGAT
04700 *VERLIEZ
04710 *VERLIES
04720 ØVERLOOR
04730 ØVERLOR
04740 ØVERSLIND
04750 ØVERSLOND
04760 *VIND
04770 ØVOND
04780 *VLECHT
04790 ØVLOCHT
04800 *VLIEG
04810 ØVLOOG
04820 ØVLOG
04830 ØVLIET
04840 ØVLOOT
04850 ØVLOT
04860 ØVOUW
04870 ØVRAAG
04880 ØVRAG
04890 ØVROEG
04900 ØVREET
04910 ØVRET
04920 ØVRAT
04930 *VRIEZ
04940 ØVRIES
04950 ØVROOR
04960 ØVROR
04970 ØWAAI
04980 ØWOEI
04990 ØWASS
05000 ØWAS
05010 ØWIES
05020 ØWEEG
05030 *WEG
05040 ØWOOG
05050 ØWOG
05060 *WERP
05070 ØWIERP
05080 ØWORP
05090 ØWERF
05100 ØWERV
05110 ØWIERF
05120 ØWIERV
05130 ØWORV
05140 ØWEET
05150 ØWET
05160 ØWIST
05170 ØWEEF
05180 ØWEV
05190 *WIJK
05200 ØWEEK
05210 ØWEK
05220 *WIJT
05230 ØWET
05240 *WIJS
05250 ØWEES
05260 ØWEZ
05270 *WILL
05280 ØWIL
05290 ØWOU
05300 *WIND
05310 ØWOND
05320 *WINN
05330 *WIN
05340 ØWONN
05350 ØWON
05360 ØWORD
05370 ØWERD
05380 ØWREEK
05390 ØWREK
05400 ØWROK
05410 ØWRIJF
05420 *WRIJV
05430 ØWREEF
05440 ØWREV
05450 *WRING
05460 ØWRONG
05470 ØZEGG
05480 ØZEG
05490 ØZEI
05500 *ZEND
05510 ØZOND
05520 ØZIE
05530 ØZAG
05540 ØZIJN
05550 ØWAR
05560 *ZING
05570 ØZONG
05580 *ZINK
05590 ØZONK
05600 *ZINN
05610 *ZIN
05620 ØZONN
05630 ØZON
05640 ØZIED
05650 ØZOD
05660 *ZITT
05670 *ZIT
05680 ØZAT
05690 ØZET
05700 *ZOEK
05710 ØZOCH
05720 ØZOUT
05730 *ZUIG
05740 ØZOOG
05750 ØZOG
05760 ØZUIP
05770 ØZOOP
05780 ØZOP
05790 *ZULL
05800 ØZUL
05810 ØZAL
05820 ØZOU
05830 ØZWELG
05840 ØZWOLG
05850 *ZWELL
05860 ØZWEL
05870 ØZWOLL
05880 ØZWOL
05890 *ZWEMM
05900 ØZWEM
05910 ØZWOMM
05920 ØZWOM
05930 *ZWEER
05940 *ZWER
05950 ØZWOER
05960 ØZWOOR
05970 ØZWOR
05980 *ZWERF
05990 *ZWERV
06000 ØZWIERF
06010 ØZWIERV
06020 ØZWORV
06030 *ZWIJG
06040 ØZWEEG
06050 ØZWEG
```

Pour l'allemand :

Une analyse plus précise requiert un code plus complet. Le code actuel utilisé dans .MORPHAL(VERBRG) a trois caractères :

"1" en première position signifie qu'il s'agit d'un verbe régulier.

"*" en seconde position : verbe à préverbe inséparable. L'absence de ge- et la terminaison -et ou -t n'impliquera pas l'indicatif présent seul. Il y aura ambiguïté avec le participe passé.

"#" en seconde position : le ge- est ambigu pour certaines formes. C'est la série *Gebrauchen, gedulden, gehorchen, gehören....* que nous étudierons au paragraphe 4.3.6.3.2.2

"&" en troisième position : verbes en **-eln** ou **-ern**

"2" en troisième position : le radical se retrouve dans le fichier des verbes irréguliers :

GELANG --> GELINGEN (a-u) réussir
--> GELANGEN arriver

.MORPHAL(VERBRG) :

```
00020 811
00030 0030
00040 6334
00050 100ACHT
00060 100A*CHT
00070 100A*CHZ
00080 101ACKER
00090 101A*DER
00100 100AHN
00110 102A*HNEL
00120 100AHN
00130 101ALTER
00140 103A*NDER
00150 100ARBEIT
00160 103A*RGER
00170 100ATM
00180 103A*US*ER
00190 100BAD
00200 100BAHN
00210 100BAU
00220 1*0BEFREI
00230 1*0BEGU*NSTIG
00240 1*0BEND*TIG
00250 1*0BEREIT
00260 101BESSER
00270 1*0BETEILIG
00280 1*0BEWA*HR
00290 1*0BEWEG
00300 100BILD
00310 100BLICK
00320 100BLICK
00330 100BRAUCH
00340 100BREIT
00350 100BRENG
00360 102BRU*T
00370 103DA*NNER
00380 1000A*NN
00390 100DAMPF
00400 102DA*MPF
00410 100DANK
00420 100DARB
00430 100DARR
00440 101DAUER
00450 100DAU
00460 100DECK
00470 100DEHN
00480 103DENGEL
00490 100DEUTLICH
00500 100DEUT
00510 100DICHT
00520 100DIEN
00530 103DOPPEL
00540 1000D*RR
00550 100DRAHT
00560 101DRA*NGEL
00570 101DRESCHEL
00580 100DREH
```

```
00590 100DRILL
00600 101DRITTEL
00610 100DROH
00620 100DRO*HN
00630 101DROSSEL
00540 100DRUCK
00650 100DRU*CK
00660 100DRUSCH
00670 100DUCK
00680 100DUFT
00690 100DULD
00700 101DUNKEL
00710 100DUNST
00720 100DU*NST
00730 100DUSCH
00740 100EHR
00750 101EIFER
00760 100EIGN
00770 100EIL
00780 100EIS
00790 100ENDIG
00800 100END
00810 100ENG
00820 100ERB
00830 1*0ERNO*GLICH
00840 1*0ERNUTIG
00850 101FA*CHEL
00860 100FA*LSCH
00870 100FALT
00880 100FA*RB
00890 101FASER
00900 100FASS
00910 100FAS*
00920 101FEDER
00930 100FEG
00940 100FEIL
00950 100FERN
00960 100FERTIG
00970 101FESSEL
00980 100FESTIG
00990 100FEUCHT
01000 101FEUER
01010 101FIEBER
01020 100FILM
01030 100FLANSCH
01040 101FLATTER
01050 100ELEH
01060 100FLICK
01070 100FLO*H
01080 101FLU*CHT
01090 100FISCH
01100 100FLUSS
01110 100FLUT
01120 100FOLG
01130 101FORDER
01140 101FO*RDER
01150 100FORM
01160 100FORSCH
01170 100FRAG
01180 100FRA*S
01190 100FREU
01200 100FRIEDIG
01210 100FRISCH
01220 100FRIST
01230 100FUG
01240 100FU*G
01250 100FU*HL
01260 100FU*HR
01270 100FU*LL
01280 101FUHKEL
01290 100FUNK
01300 101FUTTER
01310 101FU*TTER
01320 100FU*RCHT
01330 101GABEL
01340 100GA*HN
01350 100GA*NZ
01360 100GAS
01370 1N0GEBRAUCH
01380 1N0GEDULD
01390 1N0GEHORCH
01400 1N0GEHO*R
01410 1N0GELEIT
01420 1N0GELOB
01430 1N0GEREICH
01440 1N0GEREU
01450 1N0GERUH
01460 1N0GESEGN
01470 1N0GETRAU
01480 1N0GEWAHR
01490 1N0GEWA*HR
01500 1N0GEZIEH
01510 1*0GEBAR
01520 1*0GEBA*RD
01530 1*0GEBU*HR
01540 1*0GEFA*HRD
01550 1*2GELANG
01560 1*0GELU*ST
01570 1*0GENU*G
01580 100GEGN
01590 101GEIFER
01600 101GEIS*EL
01610 100GEIZ
01620 100GELL
01630 1*0GENE*HMIG
01640 100GERS
01650 1*0GESELL
01660 1*0GESTALT
01670 1*0GESTATT
01680 1*0GEWA*HRLEIST
01690 1*0GEWA*LTIG
01700 1*0GEWA*RTIG
01710 1*0GEWO*HN
01720 100GIER
01730 100GIFT
01740 101GIPFEL
01750 100GIPS
01760 100GLA*NZ
01770 100GLAS
01780 100GLATT
01790 100GLAUB
01800 100GLEIS
01810 101GLIEDER
01820 100GLITSCH
01830 101GLITZER
01840 100GLU*CK
01850 100GLU*H
01860 100GNU*G
01870 100GOLD
01880 100GO*NN
01890 100GRAU
01900 100GRENZ
01910 100GRILL
01920 100GRU*ND
01930 100GRU*S*
01940 100GUCK
01950 100GU*RT
01960 100GU*T
01970 100HA*CK
01980 100HAFT
01990 101HAGEL
02000 100HAK
02010 100HALL
02020 101HA*HNER
02030 101HANDEL
02040 100HARK
02050 100HARN
02060 100HARR
02070 100HA*RT
02080 101HASPEL
02090 100HAST
02100 100HAUCH
02110 101HA*UFEL
02120 101HECHEL
02130 100HEFT
02140 100HEG
02150 100HEHL
02160 100HEIL
02170 101HEISCH
02180 100HEIZ
02190 100HELL
02200 100HELLIG
02210 100HEHN
02220 100HEHX
02230 100HERBERG
```

```
02240 100HERRSCH
02250 100HERZ
02260 100HETZ
02270 103HEUCHEL
02280 103HINDER
02290 100HINK
02300 100HITZ
02310 103HOBEL
02320 100HOCK
02330 100HOFF
02340 100HO*H
02350 100HO*HL
02360 100HOL
02370 100HOLZ
02380 100HORCH
02390 103HO*R
02400 100HORST
02410 100HORT
02420 100HULDIG
02430 100HU*LL
02440 103HUMPEL
02450 103HUNGER
02460 100HU*PF
02470 100HUSCH
02480 100HUST
02490 100HU*T
02500 103INNER
02510 100IRR
02520 100JAG
02530 103JAMMER
02540 100JAUL
02550 103KABEL
02560 100KALK
02570 100KA*LT
02580 100KA*MPF
02590 103KAPSEL
02600 100KAU
02610 100KAUF
02620 100KEHL
02630 100KEHR
02640 103KEIL
02650 100KEIM
02660 100KERB
02670 100KETT
02680 100KEUCH
02690 103KIPPEL
02700 100KIPP
02710 100KITT
02720 100KLAFF
02730 103KLAG
02740 103KLAMMER
02750 100KLAPP
02760 103KLAPPER
02770 100KLAPS
02780 100KLA*R
02790 103KLATSCH
02800 100KLEB
02810 100KLEID
02820 103KLEISTER
02830 100KLEmM
02840 103KLETTER
02850 103KLIMPER
02860 103KLINGEL
02870 100KLIRR
02880 100KLOPF
02890 100KNACK
02900 100KNALL
02910 100KNET
02920 100KNICK
02930 100KNI
02940 103KNIPS
02950 100KNO*PF
02960 100KNOT
02970 100KNU*PF
02980 100KOCH
02990 100KOHL
03000 103KOPPEL
03010 100KORK
03020 100KO*RN
03030 100KOST
03040 100KRACH
03050 103KRAKEL
03060 100KRALL
03070 100KRAM
03080 100KRAMPF
03090 100KRANK
03100 100KRATZ
03110 103KREMPEL
03120 100KREPP
03130 100KREUZ
03140 100KREUZIG
03150 103KRIBBEL
03160 100KRIES
03170 100KRO*N
03180 100KRO*PF
03190 103KRU*mEL
03200 100KRUM
03210 100KRU*mM
03220 103KUGEL
03230 100KU*HL
03240 103KU*mMER
03250 100KUND
03260 100KU*NDIG
03270 100KU*nD
03280 103KUPFER
03290 103KUPFEL
03300 103KUPPEL
03310 103KURBEL
03320 100KU*RZ
03330 100LACH
03340 100LACK
03350 103LAGER
03360 100LA*HM
03370 100LAND
03380 100LA*RM
03390 100LAST
03400 103LA*STER
03410 100LAUB
03420 100LATSCH
03430 103LAUER
03440 100LAUSCH
03450 100LAUT
03460 103LA*UTER
03470 100LA*UT
03480 100LEB
03490 100LECK
03500 103LEDER
03510 100LEG
03520 100LEHN
03530 103LEHR
03540 100LEIB
03550 103LEICHTER
03560 103LEIER
03570 100LEIM
03580 100LEIST
03590 100LEIT
03600 100LENK
03610 100LERN
03620 100LEUCHT
03630 100LIEB
03640 103LIEFER
03650 100LIST
03660 100LOB
03670 100LOCH
03680 100LOCK
03690 100LOHN
03700 103LO*SCH
03710 100LOS
03720 100LO*S
03730 100mACH
03740 100mA*H
03750 100mA*CHTIS
03760 100mAHL
03770 100mAHN
03780 100mA*HR
03790 103mANGEL
03800 100mARK
03810 100mASS
03820 100mAS*
03830 100mA*S*IG
03840 103mATT
03850 103mAUER
03860 100mEHR
03870 100mEIN
03880 103mEISTER
```

```
03890 100HELD
03900 100HENG
03910 100HERK
03920 101HESSER
03930 100HIET
03940 102HILDER
03950 100HISCH
03960 101HITTEL
03970 100HIX
03980 100HU*H
03990 101HUSTER
04000 100NACHLA*SSIG
04010 100NACHT
04020 101NADEL
04030 101NAGEL
04040 100NA*H
04050 100NA*HR
04060 100NA*SS
04070 101NEBEL
04080 100NEID
04090 100NEIG
04100 100NERV
04110 100NETZ
04120 101NEUER
04130 100NICK
04140 100NORM
04150 100NO*TIG
04160 100NOT
04170 100NUTZ
04180 100NU*TZ
04190 1000*D
04200 1000*FFN
04210 101OPFER
04220 1010*RTER
04230 101ORDER
04240 100ORDN
04250 100PACK
04260 100PARK
04270 100PRELL
04280 100PRESS
04290 100PASS
04300 100PACH
04310 100PLAN
04320 100PROB
04330 100PRU*F
04340 100PO*HN
04350 101PRU*GEL
04360 101PUDER
04370 100PULS
04380 101PULVER
04390 100PUMP
04400 100PUNKT
04410 100PUTZ
04420 100QUA*L
04430 102QUATSCH
04440 100QUER
04450 100QUETSCH
04460 100QUICK
04470 101RA*DER
04480 100RAG
04490 100RAHM
04500 100RAM
04510 101RA*NDER
04520 100RAS
04530 101RASSEL
04540 100RAST
04550 100RAUB
04560 100RAUCH
04570 101RA*UCHER
04580 100RA*UM
04590 100RAUSCH
04600 100RECHN
04610 100RECK
04620 100RED
04630 101REGEL
04640 100REG
04650 100REGN
04660 101REICHER
04670 100REICH
04680 100REINIG
04690 100REIS
04700 100REIZ
04710 100RETT
04720 100REU
04730 100RICHT
04740 101RIEGEL
04750 101RIESEL
04760 100RIND
04770 101RINGER
04780 100RCHR
04790 100RO*HR
04800 100ROLL
04810 101ROLLER
04820 100ROST
04830 100RO*ST
04840 100RO*T
04850 100RU*CK
04860 101RUDER
04870 100RUH
04880 100RU*HR
04890 100RU*HR
04900 101RUMPEL
04910 100RUND
04920 102RUPF
04930 100RU*ST
04940 101RU*TTEL
04950 100SACH
04960 100SACK
04970 100SAG
04980 100SA*G
04990 100SA*TTIG
05000 101SAMMEL
05010 100SAND
05020 101SATTEL
05030 100SA*UG
05040 100SAUS
05050 100SA*UM
05060 100SCHAD
05070 100SCHA*DIG
05080 100SCHALT
05090 100SCHA*FTIG
05100 101SCHAL
05110 100SCHA*RF
05120 100SCHARR
05130 102SCHASS
05140 100SCHATT
05150 100SCHA*TZ
05160 101SCHAUKEL
05170 101SCHAUDER
05180 102SCHAULICH
05190 100SCHAU
05200 100SCHA*UM
05210 100SCHELL
05220 100SCHENK
05230 101SCHEITER
05240 100SCHEU
05250 100SCHICHT
05260 100SCHICK
05270 100SCHIFF
05280 101SCHILDER
05290 101SCHIMMER
05300 100SCHIMPF
05310 100SCHIRM
05320 100SCHIRR
05330 100SCHLACHT
05340 100SCHLEIM
05350 101SCHLECHTER
05360 101SCHLEIER
05370 101SCHLENDER
05380 100SCHLEUNIG
05390 100SCHLEUS
05400 100SCHLICHT
05410 100SCHLU*PF
05420 100SCHMECK
05430 101SCHMEICHEL
05440 101SCHMA*LER
05450 100SCHMERZ
05460 100SCHMIED
05470 100SCHMIER
05480 101SCHMIGGEL
05490 100SCHMUTZ
05500 100SCHMALL
05510 100SCHNAPP
05520 100SCHNARR
05530 100SCHNAUF
```

```
05540 100SCHNAUZ
05550 100SCHNEI
05560 103SCHNITZEL
05570 100SCHNITZ
05580 103SCHNU*FFEL
05590 100SCHNU*R
05600 100SCHNURR
05610 100SCHON
05620 100SCHO*PF
05630 100SCHRA*NK
05640 100SCHRAUB
05650 100SCHROTT
05660 100SCHULD
05670 100SCHUL
05680 103SCHU*TTEL
05690 100SCHU*TT
05700 103SCHU*TTER
05710 100SCHU*TZ
05720 100SCHWA*CH
05730 100SCHWANCK
05740 103SCHWA*RM
05750 100SCHWA*RZ
05760 100SCHWATZ
05770 100SCHWA*TZ
05780 100SCHWEB
05790 103SCHWEFEL
05800 100SCHWEIS*
05810 100SCHWEMM
05820 100SCHWENK
05830 103SCHWINDEL
05840 100SCHWITZ
05850 103SEGEL
05860 100SEGN
05870 100SEHN
05880 100SEIF
05890 100SEIL
05900 100SA*TIG
05910 100SENG
05920 100SENK
05930 100SETZ
05940 100SEUCH
05950 100SEUFZ
05960 100SICHTIG
05970 100SICHT
05980 100SIECH
05990 103SIEDEL
06000 103SIEGEL
06010 103SINTER
06020 100SIEG
06030 100SOHL
06040 400SOLL
06050 100SONN
06060 100SORG
06070 100SPA*H
06080 120SPALT
06090 100SPANN
06100 100SPAR
06110 100SPEICH
06120 103SPEICHER
06130 100SPEIS
06140 100SPEND
06150 100SPERR
06160 103SPIEGEL
06170 100SPIEL
06180 100SPIES*
06190 100SPITZ
06200 103SPLITTER
06210 100SPOTT
06220 100SPREITZ
06230 100SPRENG
06240 100SPRITZ
06250 100SPROSS
06260 100SPRUCH
06270 103SPRUDEL
06280 100SPUCK
06290 100SPUL
06300 100SPU*L
06310 100SPUR
06320 100SPU*R
06330 100STAB
06340 103STACHEL
06350 100STAMPF
06360 100STAMM
06370 103STAPEL
06380 100STAPF
06390 100STA*RK
06400 100STARR
06410 100START
06420 100STA*TIG
06430 100STAUB
06440 100STA*UB
06450 100STAUN
06460 100STAU
06470 103STEIGER
06480 100STELL
06490 103STEMPEL
06500 103STEUER
06510 100STICK
06520 103STIEFEL
06530 100STINN
06540 103STOLPER
06550 100STOPF
06560 100STOPP
06570 100STO*R
06580 103STOTTER
06590 100STRAFF
06600 100STREIF
06610 100STRAHL
06620 100STRA*NG
06630 100STREB
06640 100STRECK
06650 103STREICHEL
06660 100STREIK
06670 100STREU
06680 100STRICK
06690 103STRICHEL
06700 100STRO*M
06710 100STU*CK
06720 103STU*CKEL
06730 100STUF
06740 100STU*RM
06750 100SCHU*RZ
06760 100STUTZ
06770 100STU*TZ
06780 100SUCH
06790 100SUMPF
06800 100SU*NDIG
06810 103TADEL
06820 103TAFEL
06830 100TAG
06840 100TANK
06850 100TANZ
06860 100TAPP
06870 100TARN
06880 100TAST
06890 100TAUCH
06900 100TAUF
06910 100TAUG
06920 103TAUNEL
06930 100TAUSCH
06940 100TAU
06950 100TAX
06960 100TEILIG
06970 100TEIL
06980 100TEST
06990 103TEUER
07000 100TEUFEL
07010 100TIPP
07020 100TEILIG
07030 100TO*N
07040 100TOPF
07050 100TO*T
07060 100TRACHT
07070 100TRA*NK
07080 100TRAU
07090 103TRAUER
07100 100TRA*UM
07110 100TRENN
07120 100TROCKN
07130 100TRAB
07140 103TRO*PFEL
07150 100TROPF
07160 100TRO*ST
07170 100TROTZ
07180 100TU*RM
```

```
07190 100TURN
07200 100U*B
07210 1*0UNTERSUCH
07220 100URSACH
07230 1*0VERBILLIG
07240 1*0VERGRO*S*ER
07250 1*0VEREINIG
07260 1*0VERLANG
07270 1*0VERMINDER
07280 1*0VERRINGER
07290 103VO*LKER
07300 103WACKEL
07310 100WAFFN
07320 100WAG
07330 100WA*HL
07340 100WAHR
07350 100WA*HN
07360 100WA*HR
07370 103WALT
07380 103WALZ
07390 100WA*LZ
07400 103WANDEL
07410 103WANDER
07420 100WA*RM
07430 100WARN
07440 100WART
07450 103WASSER
07460 103WA*SSER
07470 103WECHSEL
07480 100WECK
07490 100WEH
07500 103WEIGER
07510 100WEIH
07520 100WEIL
07530 100WEIN
07540 100WEIS*
07550 100WELK
07560 100WELL
07570 160WEND
07580 100WERK
07590 100WERT
07600 100WETT
07610 103WETTER
07620 103WICKEL
07630 100WIDM
07640 103WIEBEL
07650 100WILLIG
07660 103WIMMEL
07670 103WIMMER
07680 103WINKEL
07690 100WINK
07700 103WINTER
07710 103WIRBEL
07720 100WIRR
07730 100WIRK
07740 100WIRTSCHAFT
07750 100WISCH
07760 103WITTER
07770 100WOHN
07780 100WO*LB
07790 100WO*LK
07800 100WU*HL
07810 103WUNDER
07820 100WU*NSCH
07830 103WU*RFEL
07840 100WU*RG
07850 103WURZEL
07860 100WU*RZ
07870 100WU*ST
07880 100WU*T
07890 100ZAHL
07900 100ZA*HL
07910 160ZA?F
07920 103ZAUBER
07930 100ZA*UN
07940 100ZEICHN
07950 100ZEIG
07960 100ZICHT
07970 100ZERR
07980 100ZEUG
07990 100ZIEL
08000 100ZIEM
08010 103ZIFFER
08020 100ZINS
08030 103ZITTER
08040 103ZO*GER
08050 100ZU*CHT
08060 100ZU*CHTIG
08070 100ZUCK
08080 100ZU*CK
08090 100ZUG
08100 100ZU*ND
08110 100ZUA*NG
08120 100ZWECK
08130 103ZWEIFEL
08140 100ZWEIG
08150 100ZWICK
```

La morphologie des verbes irréguliers complique la reconnaissance des temps et le calcul de la base nécessaire à la consultation du dictionnaire de transfert.
Le premier tableau de 186 lignes permet de générer les formes. Si les données semblent très concentrées, le mécanisme de génération engendre des formes inexistantes et ne permet pas de distinguer les temps. Il a été abandonné depuis longtemps ; son seul mérite est de souligner les vertus de .MORPHAL(VERBIR), plus long puisque de 648 lignes, mais fonctionnant beaucoup plus rapidement, sans erreur et avec précision.
Chaque élément est précédé d'un nombre de deux chiffres indiquant sa longueur (pour la lecture du fichier).

La ligne 1ØØ se lit :

Ø4 B<--ND Ø1I Ø1A Ø2A* Ø1U ØØ

La forme B<--ND (composée de 4 caractères) est considérée comme un archi-segment, à partir duquel seront générées les formes BIND, BAND, BA*ND et BUND. Les modifications consonantiques sont accolées à l'archi-segment sous la forme d'un nombre de deux chiffres précédé du signe "@".

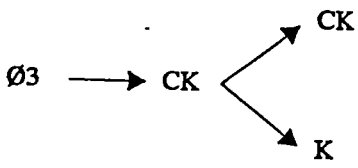

1Ø@Ø3SCHR<--CK Ø1E Ø1A Ø2A* Ø1O Ø1I ØØ

On obtient : SCHRECK, SCHRACK, SCHRA*CK, SCHROCK, SCHRICK, SCHREK, SCHRAK, SCHRA*K, SCHROK, SCHRIK

```
00010 07@@3@+CK@1A@2A*@1U@2U*@@
00020 1@@1@3FL+S*@2EI@1I@@
00030 @6DEG+NN@1I@1A@2U+@1U@@
00040 05DU+S@1E@1O@2O*@@
00050 07@1E@+S*@2EI@1I@J
00060 04@+RS@1E@1I@1A@2U+@1U@@
00070 05R+RST@1E@1I@1A@2A*@1U@@
00080 03R+S@2IE@1O@2O*@@
00090 03R+T@2IE@1O@2O*@@
00100 04R+ND@1I@1A@2A*@1U@@
00110 07@11R+IT@1I@1A@2A*@1E@@
00120 04BL+S@1A@2A*@2IE@@
00130 04BL+B@2EI@2IE@@
00140 03BL+CH@2EI@1I@@
00150 04BR+T@1A@2A+@2IE@@
00160 05BR+CH@1E@1I@1A@2A*@1U@@
00170 05BR+NN@1E@1A@@
00180 @@@@1BR+NG@@1I@1A@2A+@@
00190 07@@1D+NK@1E@1A@2A*@@
00200 04D+NG@1I@1A@2U*@1U@@
00210 04D+R@@1E@1I@1A@2U+@1U@@
00220 06DR+SCH@1E@1I@1A@2O*@1U@@
00230 05DR+NG@1I@1A@2A*@1U@@
00240 @8@1@DR+S*@2IE@1O@2O*@@
00250 07@@1D+NK@2U+@2EU@@
00260 04D+RF@2U+@1A@1U@@
00270 07ER3L+CH@2EI@1I@@
00280 06@@@+S@@1E@1I@1A@2A+@2UE@@
00290 04F+HL@1E@2IS@1A@2O+@1O@@
00300 04F+RR@1A@2A+@1U@2U+@@
00310 07@@4F+LL@1A@2A+@2IE@@
00320 04F+NG@1A@2A+@1I@@
00330 05F+CHT@1E@1I@1O@2O+@@
00340 04F+ND@1I@1A@2A+@1U@@
00350 06FL+CHT@1E@1I@1O@2O+@@
00360 04FL+S@2IE@1O@2O+@@
00370 04FL+H@2IE@1O@2O+@@
00380 @@1@FL+S+@2IE@1O@2O+@@
00390 @@2@7R+SS@1E@1I@1A@2A+@@
00400 04FR+R@2IE@1O@2O+@@
00410 03G+R@2A+@1O@2O+@@
00420 05GE3+R@2A+@2IE@1A@1O@@
00430 03G+B@1E@1I@1A@2A+@@
00440 05GED+H@2EI@2IE@@
00450 @6@@G+H@1E@1I@1A@@
00460 05GEL+NG@1I@1A@2A+@1U@@
00470 04G+LT@1E@1I@1A@2A+@1O@@
00480 05GEN+S@1E@1A@2A+@@
00490 @9@1GEN+S+@2IE@1O@2O+@@
00500 07GESCH+NN@1E@2IE@1A@2A+@@
00510 06GEU+NN@1I@1A@2A+@1U@@
00520 07@@9G+S@1E@1I@1A@2A+@@
```

```
00530 07010G←S*02IE010020*00
00540 05GL←CH02IE01I00
00550 08010GL←S*02EI01I00
00560 08011GL←TT02EI01I00
00570 05GL←MM01I010020*00
00580 04GR←B01A02A*01U020*00
00590 07002GR←F02EI01I00
00600 02H←02A002A103A*T00
00610 04H←LT01A02A*02IE00
00620 04H←NG02A*01I01A00
00630 02H←02AJ03IE000
00640 03H←B01E010020*01U02U*00
00650 04H←S*02EI02IE00
00660 04H←LF01E01I01A02U*01000
00670 03K←S02IE010020*00
00680 04K←NN020*01A01000
00690 05KL←MM01I010020*00
00700 05KL←NG01I01A02A*01U00
00710 07002KN←F02EI01I00
00720 07005K←MM01001A02A*00
00730 04K←NN01E01A00
00740 05KR←CH02IE010020*00
00750 03L←D01A01U02U*02A*00
00760 07009L←SS01A02A*02IE00
00770 03L←F02AU03A*U02IE00
00780 06012L←D02EI01I00
00790 03L←H02EI02IE00
00800 03L←R02IE010020*00
00810 03L←S01E02IE01A02A*00
00820 03L←G02IE01A02A*01E00
00830 03L←G02U*010020*00
00840 05L←SCH020*01I01000
00850 03M←D02EI02IE00
00860 04M←LK01E020*01000
00870 07009M←SS01E01I01A02A*00
00880 06001M←G020*01A01000
00890 07009M←SS02U*01U00
00900 07005N←HM01E01I01A02A*01000
00910 04N←NN01E01A00
00920 07002PF←F02EI01I00
00930 05PFL←G01E010020*00
00940 04PR←S02EI02IE00
00950 05QU←LL01E01I010020*00
00960 03R←T01A02A*02IE00
00970 03R←B02EI02IE00
00980 07012R←S*02EI01I00
00990 07011R←TT02EI01I00
01000 04R←NN01E01A00
01010 04R←CH02IE010020*00
01020 04R←NG01I01A02A*01U00
01030 04R←NN01I01A02A*01000
01040 03R←F01U02IE00
01050 06002S←F02AU03A*U010020*00
01060 03S←G02AU010020*00
01070 09013SCH←FF01A01U02U*00
01080 06SCH←LL01A010020*00
01090 05SCH←D02EI02IE00
01100 05SCH←N02EI02IE00
01110 06SCH←LT01E01I01A020*01000
01120 05SCH←R01E02IE010020*00
01130 05SCH←B02IE010020*00
01140 09010SCH←S*02IE010020*00
01150 06SCH←ND01I01U02U*00
01160 06SCHL←F01A02A*02IE00
01170 09002SCHL←F02EI01I00
01180 06SCHL←G01A02A*01U02U*00
01190 07SCHL←CH02EI01I00
01200 09002SCHL←F02EI01I00
01210 10010SCHL←S*02EI01I00
01220 10010SCHL←S*02IE010020*00
01230 07SCHL←NG01I01A02A*01U00
01240 10010SCHM←S*02EI01I00
01250 07SCHM←LZ01E01I010020*00
01260 06SCHN←B02AU010020*00
01270 09012SCHN←D02EI01I00
01280 10003SCHR←CK01E01A02A*01001I00
01290 06SCHR←B02EI02IE00
01300 10011SCHR←TT02EI02IT00
01310 05SCHR←02EI02IE00
01320 06SCHW←G02EI02IE00
01330 07SCHW←LL01E01I010020*00
01340 07SCHW←MM01I01A02A*010020*00
01350 07SCHW←ND01I01A02A*01U00
01360 07SCHW←NG01I01A02A*01U00
01370 06SCHW←R020*01002U*01U00
01380 03S←H01E02IE01A02A*00
01390 04S←ND01E01A00
01400 06012S←D02IE010020*00
01410 04S←NG01I01A02A*01U00
01420 04S←NK01I01A02A*01U00
01430 04S←NN01I01A02A*020*01000
01440 07009S←TZ01I01A02A*01E00
01450 03SP←02EI02IE00
01460 05SP←NN01I01A02A*020*01000
01470 06SPR←CH01E01I01A02A*01000
01480 09010SPR←S*02IE010020*00
01490 06SPR←NG01I01A02A*01U00
01500 05ST←CH01E01I01A02A*01000
01510 08003ST←CK01E01A02A*00
01520 07007ST←H01E01A02A*02U*00
01530 05ST←HL01E02IE01A020*01000
01540 04ST←S02EI02IE00
01550 05ST←R01E01I01A02U*01000
01560 04ST←B02IE010020*00
01570 05ST←NK01I01A02A*01U00
01580 05ST←S*010020*02IE00
01590 05STR←CH02EI01I00
01600 09011STR←TT02EI01I00
01610 04TR←G01A02A*01U02U*00
01620 09013TR←FF01E01I01A02A*01000
01630 04TR←B02EI02IE00
01640 08011TR←TT01E01I01A02A*00
01650 07002TR←F02IE010020*00
01660 05TR←NK01I01A02A*01U00
01670 04TR←G02U*010020*00
01680 02T←01U01A02A*00
01690 05W←CHS01A02A*01U02U*00
01700 03W←G02A*010020*00
01710 05W←SCH01A02A*01U02U*00
01720 03W←R01A02A*00
01730 03W←B01E010020*00
01740 04W←CH02EI01I00
01750 03W←S02EI02IE00
01760 04W←ND01E01A00
01770 04U←R01E01I01A02U*01000
01780 04U←RD01E01I01U02U*01000
01790 04U←RF01E01I01A02U*01000
01800 03W←G02IE010020*00
01810 04U←ND01I01A02A*01U00
01820 07009W←SS01I02EI01U02U*00
01830 04W←LL01001I00
01840 03Z←H02EI02IE00
01850 06014Z←H02IE010020*00
01860 05ZW←NG01I01A02A*01U00
END OF DATA
```

Le code utilisé dans .MORPHAL(VERBIR) a quatre chiffres.

Position 1 : type de verbe	2	verbe irrégulier
	3	auxiliaire
	4	prétérito-présent
	7	mixte
Position 2,3 et 4 : Conjugaison	1	infinitif/présent indicatif
	2	prétérit
	3	participe passé
	4	prétérit/participe passé
	6	présent indicatif
	7	subjonctif
	8	participe passé ambigu (GE)FROREN

Aprés le tiret, le radical de l'infinitif correspondant.

.MORPHAL(VERBIR) :

```
00540 2600BIRG-BERG
00550 2200BARG-BERG
00560 2700BU*RG-BERG
00570 2700BA*RG-BERG
00580 2300BORG-BERG
00590 2100BERST-BERST
00600 2600BIRST-BERST
00610 2200BARST-BERST
00620 2300BORST-BERST
00630 2700BA*RST-BERST
00640 2700BO*RST-BERST
00650 2100BIEG-BIEG
00660 2400BOG-BIEG
00670 2700BO*G-BIEG
00680 2100BIET-BIET
00690 2400BOT-BIET
00700 2700BO*T-BIET
00710 2100BIND-BIND
00720 2200BAND-BIND
00730 2700BA*ND-BIND
00740 2300BUND-BIND
00750 2100BITT-BITT
00760 2200BAT-BITT
00770 2700BA*T-BITT
00780 2300BET-BITT
00790 2130BLAS-BLAS
00800 2602BLA*S-BLAS
00810 2200BLIES-BLAS
00820 2100BLEIB-BLEIB
00830 2400BLIEB-BLEIB
00840 2130BRAT-BRAT
00850 2600BRA*T-BRAT
00860 2200BRIET-BRAT
00870 2200BRACH-BRECH
00880 7400BRACH-BRING
00890 2700BRA*CH-BRECH
00900 7700BRA*CH-BRING
00910 2100BRECH-BRECH
00920 7100BRING-BRING
00930 2300BROCH-BRECH
00940 2600BRICH-BRECH
00950 2100BRENN-BRENN
00960 7400BRANN-BRENN
00970 7100DENK-DENK
00980 7400DACH-DENK
00990 7700DA*CH-DENK
01000 2100DRESCH-DRESCH
01010 2600DRISCH-DRESCH
01020 2400DROSCH-DRESCH
01030 2700DRO*SCH-DRESCH
01040 2100DRING-DRING
01050 2200DRANG-DRING
01060 2700DRA*NG-DRING
01070 2300DRUNG-DRING
01080 2100EMPFEHL-EMPFEHL
01090 2600EMPFIEHL-EMPFEHL
01100 2200EMPFAHL-EMPFEHL
01110 2700EMPFO*HL-EMPFEHL
01120 2300EMPFOHL-EMPFEHL
01130 2100ERBLEICH-ERBLEICH
01140 2400ERBLICH-ERBLEICH
01150 2100ERKIES-ERKIES
01160 2400ERKOR-ERKIES
01170 2700ERKO*R-ERKIES
01180 2100ERLO*SCH-ERLO*SCH
01190 2600ERLISCH-ERLO*SCH
```

```
01200 2400ERLOSCH-ERLO*SCH
01210 2100ESS-ESS
01220 2600IS*-ESS
01230 2200AS*-ESS
01240 2700A*S*-ESS
01250 2300GESS-ESS
01260 2130FAHR-FAHR
01270 2600FA*HR-FAHR
01280 2200FUHR-FAHR
01290 2700FU*HR-FAHR
01300 2130FALL-FALL
01310 2600FA*LL-FALL
01320 2200FIEL-FALL
01330 2130FANG-FANG
01340 2700FA*NG-FANG
01350 2200FING-FANG
01360 2100FECHT-FECHT
01370 2600FICHT-FECHT
01380 2400FOCHT-FECHT
01390 2700FO*CHT-FECHT
01400 2100FIND-FIND
01410 2200FAND-FIND
01420 2300FUND-FIND
01430 2700FA*ND-FIND
01440 2100FLECHT-FLECHT
01450 2600FLICHT-FLECHT
01460 2400FLOCHT-FLECHT
01470 2700FLO*CHT-FLECHT
01480 2100FLIEG-FLIEG
01490 2400FLOG-FLIEG
01500 2700FLO*G-FLIEG
01510 2100FLIEH-FLIEH
01520 2400FLOH-FLIEH
01530 2700FLO*H-FLIEH
01540 2100FLIES*-FLIES*
01550 2200FLOS*-FLIES*
01560 2300FLOSS-FLIES*
01570 2700FLO*SS-FLIES*
01580 2130FRESS-FRESS
01590 2600FRIS*-FRESS
01600 2200FRAS*-FRESS
01610 2700FRA*S*-FRESS
01620 2100FRIER-FRIER
01630 2400FROR-FRIER
01640 2700FRO*R-FRIER
01650 2100GA*R-GA*R
01660 2400GOR-GA*R
01670 2700GO*R-GA*R
01680 2100GEBA*R-GEBA*R
01690 2600GEBIER-GEBA*R
01700 2200GEBAR-GEBA*R
01710 2300GEBOR-GEBA*R
01720 2700GEBO*R-GEBA*R
01730 2100GEBRECH-GEBRECH
01740 2600GEBRICH-GEBRECH
01750 2400GEBROCH-(GE)BRECH
01760 2100GEDENK-GEDENK
01770 2400GEDACH-(GE)DENK
01780 2100GERINN-GERINN
01790 2200GERANN-GERINN
01800 2300GERONN-(GE)RINN
01810 2100GEBIET-GEBIET
01820 2400GEBOT-(GE)BIET
01830 2100GEFRIER-GEFRIER
01840 2400GEFROR-(GE)FRIER
01850 2100GESTEH-GESTEH
01860 2400GESTAND-(GE)STEH
01870 2130GEFALL-(GE)FALL
01880 2200GEFIEL-GEFALL
01890 2120GERAT-(GE)RAT
01900 2200GERIET-GERAT
01910 2130GEB-GEB
01920 2600GIB-GEB
01930 2200GAB-GEB
01940 2700GA*B-GEB
01950 2100GEDEIH-GEDEIH
01960 2400GEDIEH-GEDEIH
01970 2100GEH-GEH
01980 2200GING-GEH
01990 2300GANG-GEH
02000 2100GELING-GELING
02010 2200GELANG-GELING
02020 2700GELA*NG-GELING
02030 2300GELUNG-GELING
02040 2100GELT-GELT
02050 2600GILT-GELT
02060 2200GALT-GELT
02070 2700GO*LT-GELT
02080 2700GA*LT-GELT
02090 2300GOLT-GELT
02100 2130GENES-GENES
02110 2200GENAS-GENES
02120 2700GENA*S-GENES
02130 2100GENIES*-GENIES*
02140 2200GENOS*-GENIES*
02150 2300GENOSS-GENIES*
02160 2700GENO*SS-GENIES*
02170 2130GESCHEH-GESCHEH
02180 2600GESCHIEH-GESCHEH
02190 2200GESCHAH-GESCHEH
02200 2700GESCHA*H-GESCHEH
02210 2100GEWINN-GEWINN
02220 2200GEWANN-GEWINN
02230 2700GEWO*NN-GEWINN
02240 2700GEWA*NN-GEWINN
02250 2300GEWONN-GEWINN
02260 2100GIES*-GIES*
02270 2200GOS*-GIES*
02280 2300GOSS-GIES*
02290 2700GO*S*-GIES*
02300 2100GLEICH-GLEICH
02310 2400GLICH-GLEICH
02320 2100GLEIT-GLEIT
02330 2400GLITT-GLEIT
02340 2100GLIMM-GLIMM
02350 2400GLOMM-GLIMM
02360 2700GLO*MM-GLIMM
02370 2130GRAB-GRAB
02380 2700GRA*B-GRAB
02390 2200GRUB-GRAB
02400 2700GRU*B-GRAB
02410 2100GREIF-GREIF
02420 2400GRIFF-GREIF
02430 2130HALT-HALT
02440 2600HA*LT-HALT
02450 2200HIELT-HALT
02460 2120HA*NG-HA*NG
02470 2300HANG-HA*NG
02480 2200HING-HA*NG
02490 2130HAU-HAU
02500 2200HIEB-HAU
02510 2100HEB-HEB
```

```
02520 2400HOB-HEB
02530 2700HO*B-HEB
02540 2130HEIS*-HEIS*
02550 2200HIES*-HEIS*
02560 2100HELF-HELF
02570 2600HILF-HELF
02580 2200HALF-HELF
02590 2700HU*LF-HELF
02600 2300HOLF-HELF
02610 2100KENN-KENN
02620 7400KANN-KENN
02630 2100KLInn-KLInn
02640 2400KLOnn-KLInn
02650 2700KLO*nn-KLInn
02660 2100KLING-KLING
02670 2200KLANG-KLING
02680 2700KLA*NG-KLING
02690 2300KLUNG-KLING
02700 2100KNEIF-KNEIF
02710 2400KNIFF-KNEIF
02720 2130KOnn-KOnn
02730 2200KAn-KOnn
02740 2700KA*n-KOnn
02750 2100KRIECH-KRIECH
02760 2400KROCH-KRIECH
02770 2700KRO*CH-KRIECH
02780 2130LAD-LAD
02790 2600LA*D-LAD
02800 2200LUD-LAD
02810 2700LU*D-LAD
02820 2100LASS-LASS
02830 2600LA*S*-LASS
02840 2200LIES*-LASS
02850 2200LAS*-LASS
02860 2130LAUF-LAUF
02870 2600LA*UF-LAUF
02880 2200LIEF-LAUF
02890 2100LEID-LEID
02900 2400LITT-LEID
02910 2100LEIH-LEIH
02920 2400LIEH-LEIH
02930 2130LES-LES
02940 2600LIES-LES
02950 2200LAS-LES
02960 2700LA*S-LES
02970 2100LIEG-LIEG
02980 2200LAG-LIEG
02990 2700LA*G-LIEG
03000 2300LEG-LIEG
03010 2100LU*G-LU*G
03020 2400LOG-LU*G
03030 2700LO*G-LU*G
03040 2100nEID-nEID
03050 2400nIED-nEID
03060 2100nELK-nELK
03070 2600nILK-nELK
03080 2400nOLK-nELK
03090 2130nESS-nESS
03100 2100nIS*LING-nIS*LING
03110 2200nIS*LANG-nIS*LING
03120 2700nIS*LA*NG-nIS*LING
03130 2300nIS*LUNG-nIS*LING
03140 2600nIS*-nESS
03150 2200nAS*-nESS
03160 2700nA*S*-nESS
03170 2100nEHn-nEHn
03180 2600nInn-nEHn
03190 2200nAHn-nEHn
03200 2700nA*Hn-nEHn
03210 2300nOnn-nEHn
03220 7100nEnn-nEnn
03230 7400nAnn-nEnn
03240 2100PFEIF-PFEIF
03250 2400PFIFF-PFEIF
03260 2100PFLEG-PFLEG
03270 2400PFLOG-PFLEG
03280 2700PFLO*G-PFLEG
03290 2100PREIS-PREIS
03300 2400PRIES-PREIS
03310 2100QUELL-QUELL
03320 2600QUILL-QUELL
03330 2400QUOLL-QUELL
03340 2700QUO*LL-QUELL
03350 2130RAT-RAT
03360 2600RA*T-RAT
03370 2200RIET-RAT
03380 2100REIB-REIB
03390 2400RIEB-REIB
03400 2100REIS*-REIS*
03410 2200RIS*-REIS*
03420 2300RISS-REIS*
03430 2100REIT-REIT
03440 2400RITT-REIT
03450 7100RENN-RENN
03460 7400RANN-RENN
03470 2100RIECH-RIECH
03480 2400ROCH-RIECH
03490 2700RO*CH-RIECH
03500 2100RING-RING
03510 2200RANG-RING
03520 2700RA*NG-RING
03530 2300RUNG-RING
03540 2100RINN-RINN
03550 2200RANN-RINN
03560 2700RA*NN-RINN
03570 2700RO*NN-RINN
03580 2300RONN-RINN
03590 2130RUF-RUF
03600 2200RIEF-RUF
03610 2100SAUF-SAUF
03620 2600SA*UF-SAUF
03630 2400SOFF-SAUF
03640 2700SO*FF-SAUF
03650 2100SAUG-SAUG
03660 2400SOG-SAUG
03670 2700SO*G-SAUG
03680 2130SCHAFF-SCHAFF
03690 2200SCHUF-SCHAFF
03700 2700SCHU*F-SCHAFF
03710 2100SCHALL-SCHALL
03720 2200SCHOLL-SCHALL
03730 2700SCHO*LL-SCHALL
03740 2100SCHEID-SCHEID
03750 2400SCHIED-SCHEID
03760 2100SCHEIN-SCHEIN
03770 2400SCHIEN-SCHEIN
03780 2100SCHEIS*-SCHEIS*
03790 2200SCHIS*-SCHEIS*
03800 2300SCHISS-SCHEIS*
03810 2100SCHELT-SCHELT
03820 2600SCHILT-SCHELT
03830 2200SCHALT-SCHELT
```

```
03840 2700SCHO*LT-SCHELT
03850 2300SCHOLT-SCHELT
03860 2100SCHER-SCHER
03870 2600SCHIER-SCHER
03880 2400SCHOR-SCHER
03890 2700SCHO*R-SCHER
03900 2100SCHIEB-SCHIEB
03910 2400SCHOS-SCHIEB
03920 2700SCHO*B-SCHIEB
03930 2100SCHIES*-SCHIES*
03940 2200SCHOS*-SCHIES*
03950 2300SCHOSS-SCHIES*
03960 2700SCHO*SS-SCHIES*
03970 2100SCHIND-SCHIND
03980 2400SCHUND-SCHIND
03990 2700SCHU*ND-SCHIND
04000 2130SCHLAF-SCHLAF
04010 2600SCHLA*F-SCHLAF
04020 2200SCHLIEF-SCHLAF
04030 2130SCHLAG-SCHLAG
04040 2600SCHLA*G-SCHLAG
04050 2200SCHLUG-SCHLAG
04060 2700SCHLU*G-SCHLAG
04070 2130SCHLEICH-SCHLEICH
04080 2200SCHLICH-SCHLEICH
04090 2100SCHLEIF-SCHLEIF
04100 2400SCHLIFF-SCHLEIF
04110 2100SCHLEIS*-SCHLEIS*
04120 2200SCHLIS*-SCHLEIS*
04130 2300SCHLISS-SCHLEIS*
04140 2100SCHLIES*-SCHLIES*
04150 2200SCHLOS*-SCHLIES*
04160 2300SCHLOSS-SCHLIES*
04170 2700SCHLO*SS-SCHLIES*
04180 2100SCHLING-SCHLING
04190 2200SCHLANG-SCHLING
04200 2700SCHLA*NG-SCHLING
04210 2300SCHLUNG-SCHLING
04220 2100SCHMEIS*-SCHMEIS*
04230 2200SCHMIS*-SCHMEIS*
04240 2300SCHMISS-SCHMEIS*
04250 2100SCHMELZ-SCHMELZ
04260 2600SCHMILZ-SCHMELZ
04270 2400SCHMOLZ-SCHMELZ
04280 2700SCHMO*LZ-SCHMELZ
04290 2100SCHNAUB-SCHNAUB
04300 2400SCHNOB-SCHNAUB
04310 2700SCHNO*B-SCHNAUB
04320 2100SCHNEID-SCHNEID
04330 2400SCHNITT-SCHNEID
04340 2100SCHRECK-SCHRECK
04350 2600SCHRICK-SCHRECK
04360 2200SCHRAK-SCHRECK
04370 2700SCHRA*K-SCHRECK
04380 2300SCHROCK-SCHRECK
04390 2100SCHREIB-SCHREIB
04400 2400SCHRIEB-SCHREIB
04410 2100SCHREI-SCHREI
04420 2400SCHRIE-SCHREI
04430 2100SCHREIT-SCHREIT
04440 2400SCHRITT-SCHREIT
04450 2100SCHWEIG-SCHWEIG
04460 2400SCHWIEG-SCHWEIG
04470 2100SCHWELL-SCHWELL
04480 2600SCHWILL-SCHWELL
04490 2400SCHWOLL-SCHWELL
04500 2700SCHWO*LL-SCHWELL
04510 2100SCHWInn-SCHWInn
04520 2200SCHWAnn-SCHWInn
04530 2700SCHWO*nn-SCHWInn
04540 2300SCHWOnn-SCHWInn
04550 2700SCHWA*nn-SCHWInn
04560 2100SCHWIND-SCHWIND
04570 2200SCHWAND-SCHWIND
04580 2700SCHWA*ND-SCHWIND
04590 2300SCHWUND-SCHWIND
04600 2100SCHWING-SCHWING
04610 2200SCHWANG-SCHWING
04620 2700SCHWA*NG-SCHWING
04630 2300SCHWUNG-SCHWING
04640 2100SCHWO*R-SCHWO*R
04650 2400SCHWUR-SCHWO*R
04660 2700SCHWU*R-SCHWO*R
04670 2130SEH-SEH
04680 2600SIEH-SEH
04690 2200SAH-SEH
04700 2700SA*H-SEH
04710 7100SEND-SEND
04720 7400SAND-SEND
04730 2100SIED-SIED
04740 2400SOTT-SIED
04750 2700SO*TT-SIED
04760 2100SING-SING
04770 2200SANG-SING
04780 2700SA*NG-SING
04790 2300SUNG-SING
04800 2100SINK-SINK
04810 2200SANK-SINK
04820 2700SA*NK-SINK
04830 2300SUNK-SINK
04840 2100SINN-SINN
04850 2200SANN-SINN
04860 2700SA*NN-SINN
04870 2700SO*NN-SINN
04880 2300SONN-SINN
04890 2100SITZ-SITZ
04900 2200SAS*-SITZ
04910 2700SA*S*-SITZ
04920 2300SESS-SITZ
04930 2100SPEI-SPEI
04940 2400SPIE-SPEI
04950 2100SPINN-SPINN
04960 2200SPANN-SPINN
04970 2700SPO*NN-SPINN
04980 2700SPA*NN-SPINN
04990 2300SPONN-SPINN
05000 2100SPLEIS*-SPLEIS*
05010 2200SPLIS*-SPLEIS*
05020 2300SPLISS-SPLEIS*
05030 2100SPRECH-SPRECH
05040 2600SPRICH-SPRECH
05050 2200SPRACH-SPRECH
05060 2300SPROCH-SPRECH
05070 2700SPRA*CH-SPRECH
05080 2100SPRIES-SPRIES*
05090 2200SPROS*-SPRIES*
05100 2300SPROSS-SPRIES*
05110 2700SPRO*SS-SPRIES*
05120 2100SPRING-SPRING
05130 2200SPRANG-SPRING
05140 2700SPRA*NG-SPRING
05150 2300SPRUNG-SPRING
```

```
05160 2100STECH-STECH
05170 2600STICH-STECH
05180 2200STACH-STECH
05190 2700STA*CH-STECH
05200 2300STOCH-STECH
05210 2100STECK-STECK
05220 2200STAK-STECK
05230 2700STA*K-STECK
05240 2100STEH-STEH
05250 2400STAND-STEH
05260 2700STA*ND-STEH
05270 2700STU*ND-STEH
05280 2100STEHL-STEHL
05290 2600STIEHL-STEHL
05300 2200STAHL-STEHL
05310 2300STOHL-STEHL
05320 2700STO*HL-STEHL
05330 2700STA*HL-STEHL
05340 2100STEIG-STEIG
05350 2400STIEG-STEIG
05360 2100STERB-STERB
05370 2600STIRB-STERB
05380 2200STARB-STERB
05390 2700STU*RB-STERB
05400 2300STORB-STERB
05410 2100STIEB-STIEB
05420 2400STOB-STIEB
05430 2700STO*B-STIEB
05440 2100STINK-STINK
05450 2200STANK-STINK
05460 2700STA*NK-STINK
05470 2300STUNK-STINK
05480 2600STO*S*-STOS*
05490 2130STOS*-STOS*
05500 2200STIES*-STOS*
05510 2100STREICH-STREICH
05520 2400STRICH-STREICH
05530 2100STREIT-STREIT
05540 2400STRITT-STREIT
05550 2130TRAG-TRAG
05560 2600TRA*G-TRAG
05570 2200TRUG-TRAG
05580 2700TRU*G-TRAG
05590 2100TREFF-TREFF
05600 2600TRIFF-TREFF
05610 2200TRAF-TREFF
05620 2700TRA*F-TREFF
05630 2300TROFF-TREFF
05640 2100TREIB-TREIB
05650 2400TRIEB-TREIB
05660 2130TRET-TRET
05670 2600TRITT-TRET
05680 2200TRAT-TRET
05690 2700TRA*T-TRET
05700 2100TRIEF-TRIEF
05710 2400TROFF-TRIEF
05720 2700TRO*FF-TRIEF
05730 2100TRINK-TRINK
05740 2200TRANK-TRINK
05750 2700TRA*NK-TRINK
05760 2300TRUNK-TRINK
05770 2100TRU*G-TRU*G
05780 2400TROG-TRU*G
05790 2700TRO*G-TRU*G
05800 2100TU-TUN
05810 2400TA-TUN
05820 2700TA*-TUN
05830 2100VERDERB-VERDERB
05840 2600VERDIRB-VERDERB
05850 2200VERDARB-VERDERB
05860 2700VERDU*RB-VERDERB
05870 2300VERDORB-VERDERB
05880 2100VERDRIES*-VERDRIES*
05890 2200VERDROS*-VERDRIES*
05900 2300VERDROSS-VERDRIES*
05910 2700VERDRO*SS-VERDRIES*
05920 2130VERGESS-VERGESS
05930 2600VERGIS*-VERGESS
05940 2200VERGAS*-VERGESS
05950 2700VERGA*S*-VERGESS
05960 2100VERLIER-VERLIER
05970 2400VERLOR-VERLIER
05980 2700VERLO*R-VERLIER
05990 2100VERZEIH-VERZEIH
06000 2400VERZIEH-VERZEIH
06010 2130WACHS-WACHS
06020 2600WA*CHS-WACHS
06030 2200WUCHS-WACHS
06040 2700WU*CHS-WACHS
06050 2100WA*G-WA*G
06060 2400WOG-WA*G
06070 2700WO*G-WA*G
06080 2130WASCH-WASCH
06090 2600WA*SCH-WASCH
06100 2200WUSCH-WASCH
06110 2700WU*SCH-WASCH
06120 2100WEB-WEB
06130 2400WOB-WEB
06140 2700WO*B-WEB
06150 2100WEICH-WEICH
06160 2400WICH-WEICH
06170 2100WEIS-WEIS
06180 2400WIES-WEIS
06190 7100WEND-WEND
06200 7400WAND-WEND
06210 2100WERB-WERB
06220 2600WIRB-WERB
06230 2200WARB-WERB
06240 2700WU*RB-WERB
06250 2300WORB-WERB
06260 2100WERF-WERF
06270 2600WIRF-WERF
06280 2200WARF-WERF
06290 2700WU*RF-WERF
06300 2300WORF-WERF
06310 2100WIEG-WIEG
06320 2400WOG-WIEG
06330 2700WO*G-WIEG
06340 2100WIND-WIND
06350 2200WAND-WIND
06360 2700WA*ND-WIND
06370 2300WUND-WIND
06380 2100WISS-WISS
06390 7600WEIS*-WISS
06400 7400WUS*-WISS
06410 2700WU*S*T-WISS
06420 2100ZIEH-ZIEH
06430 2400ZOG-ZIEH
06440 2700ZO*G-ZIEH
06450 2100ZWING-ZWING
06460 2200ZWANG-ZWING
06470 2700ZWA*NG-ZWING
06480 2300ZWUNG-ZWING
END OF DATA
```

4.3.2.2.3.4 Vérification du résidu et du codage

Après avoir identifié une racine verbale, .VERBAL2 isole le résidu et le compare aux éléments du fichier des désinences .MORPHAL(DESI). Cette démarche évite les écueils du type AB-SEH-BARE ou AB et SEH peuvent faire illusion jusqu'à ce que le test de BARE suspende l'analyse.
Deux obstacles se dressent encore avant le codage de la forme verbale reconnue, la nature du "ge-" et du "zu".

1) "GE-" préverbe ou morphème du participe passé ?

Il existe trois cas de figure pour les verbes réguliers comme pour les verbes irréguliers.

a - Pour les verbes réguliers suivants : GEBÄRDEN, GEBAREN, GEBÜHREN, GENEHMIGEN, GENÜGEN, GESELLEN, GESTALTEN, GESTATTEN, GESUNDEN, GEWÄLTIGEN, GEWÄRTIGEN, GEWÖHNEN,GEFÄHRDEN, GELANGEN, GELÜSTEN, le "ge-" est toujours préverbe inséparable, d'où l'ambiguïté type GESTALTET : Présent indicatif ou Participe passé de GESTALTEN.

b - Pour les verbes réguliers suivants : GEBRAUCHEN, GEDULDEN, GEHORCHEN, GEHÖREN, GELEITEN, GELOBEN, GEREICHEN, GEREUEN, GERUHEN, GESEGNEN, GETRAUEN, GEWAHREN, GEWÄHREN, GEZIEMEN, GEMAHNEN, le "ge-" associé à la désinence "-t" ou "-et" peut être préverbe ou morphème du participe passé, d'où l'ambiguité type GEBRAUCHT : Participe passé de BRAUCHEN et de GEBRAUCHEN, Indicatif présent de GEBRAUCHEN.

c - Pour les autres verbes réguliers, 'GE' est toujours morphème du participe passé.

a1 - Pour les verbes irréguliers suivants : GEBÄREN, GEDEIHEN, GELINGEN, GENESEN, GENIEßEN, GESCHEHEN, GEWINNEN, "ge-" est préverbe quelle que soit la désinence.

ambiguïté Prétérit/Participe passé (GEDEIHEN, GENIEßEN)
ambiguïté Participe passé/Infinitif (GENESEN, GESCHEHEN)
pas d'ambiguïté de temps pour GEBÄREN (a-o), GELINGEN (a,u) et GEWINNEN (a,o).

b1 - Pour les verbes irréguliers suivants : GEBRECHEN, GEDENKEN, GERINNEN, GEBIETEN, GEFRIEREN, GESTEHEN, GEFALLEN, GERATEN, le "ge-" associé à l'alternance vocalique du participe passé et à la désinence "-en" ("-t" pour GEDENKEN) est ambigu :

- GE-préverbe/GE-participe passé pour GEBRECHEN (a-o), GEDENKEN (a-a), GEDENKEN (a,a), GERINNEN (a,o)

- Participe passé verbe préverbé/Prétérit pluriel verbe préverbé/Participe passé verbe *simple* pour GEBIETEN, GEFRIEREN, GESTEHEN

- Infinitif verbe préverbé/Indicatif présent pluriel verbe préverbé/ Participe passé verbe préverbé/Participe passé verbe préverbé/ participe passé verbe *simple* pour GEFALLEN et GERATEN

c1 - Pour tous les autres verbes irréguliers, le "ge-" est toujours associé au participe passé.

2) "ZU-" préverbe ou morphème de l'infinitif ?

Bien que l'analyse de la partie préverbale soit récursive et autorise un découpage illimité, la réalité veut qu'un préverbe composé ne puisse pas réunir plus de trois termes auquel il faut ajouter les morphèmes de l'infinitif ou du participe passé.

Associé à la désinence "-en" ou "-n" plusieurs cas vont apparaître :

- Si deux "ZU-" cohabitent dans la même composition, le second caractérise l'infinitif.

- Si "ZU-" apparaît, non précédé des seuls HIN, HER ou DA, il appartient à l'infinitif.

exemple : DAHINZUFLIEGEN

Si "ZU-" apparaît, précédé des seuls HIN, HER ou DA, il y a ambiguïté : Il est impossible de découper sans information complémentaire. Le "ZU-" est mis entre parenthèses dans les résultats.

exemple : HIN(ZU)KOMMEN HINZU/KOMMEN
HIN/KOMMEN

Lorsqu'il n'y a pas de doute sur la nature du ZU-infinitif, la forme infinitive reçoit un code spécifique qui permet de la distinguer d'un infinitif nu et de la raccrocher éventuellement, lors de l'analyse syntaxique, à des conjonctions du type UM, OHNE, ANSTATT...

3) Codage et résultats

Les sorties intermédiaires ci-dessous seront détruites après incorporation des résultats par le programme .MELANGE dans le texte complet .TRANSIT1. L'insuffisance des données en ce qui concerne le luxembourgeois et le néerlandais limite l'analyse au découpage et au calcul de la base verbale. L'obtention d'un codage tel que celui qui a été imaginé pour l'allemand suppose la transparence de nombreuses homographies due à l'absence de majuscule et dont une grande partie a déjà été résolue par une étude de contexte immédiat. Il est inutile d'aborder le codage tant que l'étape de repérage n'apporte pas de résultats parfaits.

Nous présentons le fichier .TRANSIT3 pour le luxembourgeois, le néerlandais et enfin l'allemand.

Dans la première colonne, un nombre de 5 chiffres : le numéro d'occurrence.

Dans la seconde colonne, un nombre de 9 chiffres : le nombre formé par les 5 premiers chiffres indique le numéro de la phrase.

Dans la troisième colonne : la forme verbale découpée.

Dans la quatrième colonne : la base de l'infinitif correspondant.

.TRANSIT3 pour le luxembourgeois :

```
00054 000180007    HUE T                    HUE
00055 000180015   MAT BRUECH T              MATBRUECH
00056 000190008   GE NANN T                 NANN
00057 000190010    HUE T                    HUE
00058 000190013   ENT WE>CKEL T             ENTWE>CKEL
00059 000190015    BESCHA*FTEG T            BESCHA*FTEG
00060 000200008    AS
00061 000200049   GE LUEG T                 LUEG
00062 000200059    HUE T                    HUE
00063 000210073    AS
00064 000210086  ER OP GAANG EN              EROPGAANG
00065 000220012    GE* T                    GE*
00066 000220027    FE>IER T                 FE>IER
00067 000230005    HUE T                    HUE
00068 000230016   ENT WE>CKEL T             ENTWE>CKEL
00069 000230029    HU N                     HU
00070 000230027  FEST GE SAT                FESTSAT
00071 000240004    AS
00072 000250015    BRUECH T                 BRUECH
00073 000250016    HUE T                    HUE
00074 000250018    HUE T                    HUE
00075 000250027    GEFE>IER T               GEFE>IER
00076 000250035    SIN
00077 000250041   OF HA*NK EN               OFHA*NK
00078 000250044    IMPORTE>IER EN           IMPORTE>IER
00079 000250046    EXPORTE>IER EN           EXPORTE>IER
00080 000260030   GE MAACH                  MAACH
00081 000260031    GOUF                     GOUF
00082 000270004    HA*NK T                  HA*NK
00083 000270021    EXPORTE>IER T            EXPORTE>IER
00084 000270022    GE* T                    GE*
00085 000280010    AS
00086 000280011    GRAFF                    GRAFF
00087 000290006    INTEGRE>IER TEN          INTEGRE>IER
00088 000290009    MUSS                     MUSS
00089 000290015   IWWER DENK EN             IWWERDENK
00090 000290017   U PASS EN                 UPASS
00091 000290037    SE>CHER EN               SE>CHER
00092 000300018    MUSS                     MUSS
00093 000310015   GE LE ET                  LE
00094 000310016    GI N                     GI
00095 000310025    HU N                     HU
00096 000320011    HU
00097 000320015    MISS EN                  MISS
00098 000320016   U PASS EN                 UPASS
00099 000330004    AS
00100 000330006    AS
00101 000340005    SIN
00102 000340033    GEE T                     GEE
00103 000340035    FE>IER T                  FE>IER
00104 000340040    SE>IER T                  SE>IER
00105 000350020    HE*LL T                   HE*LL
00106 000350025    GE* T                     GE*
00107 000360013    HE*L T                    HE*L
00108 000370009   ENT STI                    ENTSTI
```

```
00109 000380006     GE* T                    GE*
00110 000380055   ZE SUMMEN GEFALL           ZESUMMENGEFALL
00111 000380056     AS
00112 000390017     UA*ER TEN                UA*ER
00113 000390019     HU N                     HU
00114 000390026     FOND                     FOND
00115 000400003     GESI                     GESI
00116 000410019     HUE T                    HUE
00117 000410022     KASCH T                  KASCH
00118 000420004     HA T                     HA
00119 000420011    GE SCHAF                  SCHAF
00120 000430002    GE SOT                    SOT
00121 000430007     AS
00122 000430018     KRICH                    KRICH
00123 000430020   VIR U GAANG EN             VIRUGAANG
00124 000430041   U GE FAANG                 UFAANG
00125 000430042     HU N                     HU
00126 000430044     SPILL EN                 SPILL
00127 000430050     GE* T                    GE*
00128 000430059    VER RE>CKEL T             VERRE>CKEL
00129 000430060     HUE T                    HUE
00130 000440008     SIN
00131 000440013     DOMINE>IER T             DOMINE>IER
00132 000450003     SIN
00133 000450010   ZE SUMMEN (ZE) DIN         ZESUMMENDIN
00134 000460001    GE BAU T                  BAU
00135 000460026     GI N                     GI
00136 000470008     KRIS                     KRIS
00137 000470013     HUE T                    HUE
00138 000470021     PRODUZE>IER T            PRODUZE>IER
00139 000480004     HUE T                    HUE
00140 000480011     PRODUZE>IER T            PRODUZE>IER
00141 000480014     SIN
00142 000490003     HUE T                    HUE
00143 000490010    GE MAACH                  MAACH
00144 000490016     BESCHA*FTEG T            BESCHA*FTEG
00145 000500003     AS
00146 000500007     KOMM                     KOMM
00147 000500012    VIR AUS GONG              VIRAUSGONG
00148 000510003     AS
00149 000510014    ZERE>CK GAANG             ZERE>CKGAANG
00150 000560005     HUE T                    HUE
00151 000560018    GE SCHAF T                SCHAF
00152 000560027    VER STOPP T               VERSTOPP
00153 000560028     GOUF EN                  GOUF
00154 000570002     HUE T                    HUE
00155 000570012    GE BRAUCH T               BRAUCH
00156 000580004     HUE T                    HUE
00157 000580053     KANN T                   KANN
00158 000580054     HA T                     HA
00159 000590017   ZE SUMMEN KE>IP EN         ZESUMMENKE>IP
00160 000600006     HA TEN                   HA
00161 000600012     WAR EN                   WAR
00162 000610005     HA TE                    HA
00163 000610007    GE BAU T                  BAU
00164 000610018   ER AUS GONG EN             ERAUSGONG
```

```
00165 000620005    WAR EN                          WAR
00166 000620016   ENT STAN EN                      ENTSTAN
00167 000630002    WAR EN                          WAR
00168 000640004    HUE T                           HUE
00169 000640012    BRUECH T                        BRUECH
00170 000640019    HA T                            HA
00171 000640027    PRODUZE>IER EN                  PRODUZE>IER
00172 000640036   VER KAF EN                       VERKAF
00173 000650020    SIN
00174 000650029    LEI EN                          LEI
00175 000650033   HI REN                           HIREN
00176 000650036    AS
00177 000660002    HUE T                           HUE
00178 000660028    REVOLUTIONNE>IER T               REVOLUTIONNE>IER
00179 000660036    AS
00180 000660049    AS
00181 000670003    HU
00182 000670011    PROFITE>IER T                    PROFITE>IER
00183 000680003    LA*IT                           LA*IT
00184 000690008    AS
00185 000690012    BEAFLOSS T                      BEAFLOSS
00186 000690013    GI N                            GI
00187 000710023    BESTI N                         BESTI
00188 000720003    HU N                            HU
00189 000720006   GE WUESS ENE                     WUESS
00190 000720008   GE LIEF T                        LIEF
00191 000720012    HU
00192 000720016    ERNE>IER T                      ERNE>IER
00193 000720019   OF GE NOTZ T                     OFNOTZ
00194 000730002   VER SCHIDD ENEN                  VERSCHIDD
00195 000740007   GE WUESS ENE                     WUESS
00196 000740009    AS
00197 000740022    STI N                           STI
00198 000740028   HI ER KE*NN T                    HIERKE*NN
00199 000740036    PASS T                          PASS
00200 000750003    AS
00201 000750019  ER AN (ZE) PLANZ EN                ERANPLANZ
00202 000750028   GE WIEL T                        WIEL
00203 000750030    WAR                             WAR
00204 000760004    GEFE>IER T                      GEFE>IER
00205 000760010    HA*T T                          HA*T
00206 000760013    GESI N                          GESI
00207 000760015    HA*T T                          HA*T
00208 000760017   E*NNER LOOSS                     E*NNERLOOSS
00209 000760019    AS
00210 000760028   GE BRAUCH T                      BRAUCH
00211 000760029    GI N                            GI
00212 000760035    SICH EN                         SICH
00213 000770001   OF GESI                          OFGESI
00214 000770005    STEE T                          STEE
00215 000770019    KRICH                           KRICH
00216 000770023    HU N                            HU
00217 000780010    KE*NN T                         KE*NN
00218 000780015   FEST HAL EN                      FESTHAL
00219 000780025    SIN
00220 000780039   ENT STAN E                       ENTSTAN
```

```
00221 000790002     GOUF                    GOUF
00222 000790008     INVESTE>IER T           INVESTE>IER
00223 000790020     GI N                    GI
00224 000790021     AS
00225 000800012     KOMM                    KOMM
00226 000800013     AS
00227 000800031     REAGE>IER T             REAGE>IER
00228 000800032     HU
00229 000800036     AS
00230 000800044     KOMM                    KOMM
00231 000800061     KENN EN                 KENN
00232 000810004     AS
00233 000810008   A GE RIICHT               ARIICHT
00234 000810018   AUS ZE NOTZ EN            AUSNOTZ
00235 000820005    VER STEE T               VERSTEE
00236 000830005     PRODUZE>IER EN          PRODUZE>IER
00237 000840004     AS
00238 000850002     HU N                    HU
00239 000850006     INVESTE>IER T           INVESTE>IER
00240 000850016     PRODUZE>IER EN          PRODUZE>IER
00241 000850017     KE*NN T                 KE*NN
00242 000850023     AS
00243 000860004     SIN
00244 000860012   ER AUS KE*NN T            ERAUSKE*NN
00245 000860024    DRA SCHE>ISS T           DRASCHE>ISS
00246 000860030     STOPP EN                STOPP
00247 000870012     HUE T                   HUE
00248 000870014     AS
00249 000880004     LA*IT                   LA*IT
00250 000880018     GOUF                    GOUF
00251 000880030   OP GE BAU T               OPBAU
00252 000880031     GI N                    GI
00253 000880032     AS
00254 000890002     HA T                    HA
00255 000890022    GE ZUNN                  ZUNN
00256 000890030     MOBILISE>IER T          MOBILISE>IER
00257 000890031     HUE T                   HUE
00258 000900003     AS
00259 000910004     HU N                    HU
00260 000910016     GESI N                  GESI
00261 000910032   ER VIR GE RUFF            ERVIRRUFF
00262 000910043     WAR                     WAR
00263 000920004     SIN
00264 000920018    GE HOLL                  HOLL
00265 000920019     GI N                    GI
00266 000920026     GI N                    GI
00267 000930009    VIR GE NANN TE·          VIRNANN
00268 000930016    E*NNER HUEL EN           E*NNERHUEL
00269 000930024     GO EN                   GO
00270 000930028     ANZEFE>IER EN           ANZEFE>IER
00271 000930035   ER OF (ZE) STE*TZ EN      EROFSTE*TZ
00272 000930051     KRE>IE N                KRE>IE
00273 000940004     HUE T                   HUE
00274 000940015    GE HOLL                  HOLL
00275 000940016     GI N                    GI
00276 000940023     GI N                    GI
```

```
00277 000950011    E*NNER HUEL EN                E*NNERHUEL
00278 000950019     GO EN                        GO
00279 000950023     ANZEFE>IER EN                ANZEFE>IER
00280 000950030  ER OF (ZE) SETZ EN              EROFSETZ
00281 000950046     KRE>IE N                     KRE>IE
00282 000960004     HUE T                        HUE
00283 000960013   OF GE GRAFF                    OFGRAFF
00284 000960018     HUE T                        HUE
00285 000960023   E*M GE SAT                     E*MSAT
00286 000960037     GOUF EN                      GOUF
00287 000970008   AN ZE SETZ EN                  ANSETZ
00288 000980009     GI N                         GI
00289 000980010     AS
00290 000980014    DUER SCHLO EN                 DUERSCHLO
00291 000990010    A GAANG EN                    AGAANG
00292 000990011     AS
00293 001000013     HUE T                        HUE
00294 001000036     AGEFE>IER T                  AGEFE>IER
00295 001000040     AS
00296 001000046   OF GE SE>CHER T                OFSE>CHER
00297 001000047     GI N                         GI
00298 001010007     AS
00299 001010008    ZE SO E                       ZESO
00300 001010010   OP GE FAANG E                  OPFAANG
00301 001010011     GI N                         GI
00302 001020010     HUE T                        HUE
00303 001020018   OF GE BRACH                    OFBRACH
00304 001020037   AUS GE SPILL T                 AUSSPILL
00305 001040003     HU
00306 001040010    GE LEESCHT                    LEESCHT
00307 001040018     WAR EN                       WAR
00308 001050004     HUE T                        HUE
00309 001050010   AUS GE BAU T                   AUSBAU
00310 001050018    GE SAT                        SAT
00311 001050030     HA T                         HA
00312 001060008     HA T                         HA
00313 001060018     HUE T                        HUE
00314 001060022    GE MAACH                      MAACH
00315 001060030     LEI E                        LEI
00316 001060041    ER REECH E                    ERREECH
00317 001060042     KE*NN T                      KE*NN
00318 001070003     KONN T                       KONN
00319 001070006     RAISONNE>IER EN              RAISONNE>IER
00320 001070012     EMORGANISE>IER EN            EMORGANISE>IER
00321 001070013     SOLL T                       SOLL
00322 001070019     MISS EN                      MISS
00323 001070021     MAACH EN                     MAACH
00324 001070026   FRA*I GE STALL TE              FRA*ISTALL
00325 001070029     GESCHE>I EN                  GESCHE>I
00326 001080015   A GE SAT                       ASAT
00327 001080016     GI N                         GI
00328 001080021   NO GE DUECH T                  NODUECH
00329 001080022     HU N                         HU
00330 001080027   FRA*I GE STALL TE              FRA*ISTALL
00331 001080038    A SETZ E                      ASETZ
00332 001080039     KE*NN T                      KE*NN
```

```
00333 001090008    WAR EN                    WAR
00334 001090015    WAR EN                    WAR
00335 001090027   GE GOLL EN                 GOLL
00336 001090028    HUE T                     HUE
00337 001090030    GOUF                      GOUF
00338 001090044   GE HOLL                    HOLL
00339 001090062    GOUF E                    GOUF
00340 001090072  A GE SAT                    ASAT
00341 001100014  AUS ZE BAU EN               AUSBAU
00342 001100025 ER AN (ZE) BRE>NG EN         ERANBRE>NG
00343 001110007   BE STE*MM TEN              BESTE*MM
00344 001110011   AUS BEZUEL T               AUSBEZUEL
00345 001110012    KRUT EN                   KRUT
00346 001110014    GOUF                      GOUF
00347 001110020    LIICHT                    LIICHT
00348 001110021   GE MAACH                   MAACH
00349 001110035  IWWER ZE WIESSEL EN         IWWERWIESSEL
00350 001110045    SIN
00351 001120010    HUE T                     HUE
00352 001120019  AUS GE HOLLEF               AUSHOLLEF
00353 001120023  OF ZE DECK EN               OFDECK
00354 001120036  ER AN HUEL EN               ERANHUEL
00355 001120038    KE*NN EN                  KE*NN
00356 001130002    HA T                      HA
00357 001130015    DRO EN                    DRO
00358 001130023    HUE T                     HUE
00359 001140005    HUE T                     HUE
00360 001140012  AUS GE BIL T                AUSBIL
00361 001140026    BESCHA*FTEG EN            BESCHA*FTEG
00362 001150008    AS
00363 001160003    GI N                      GI
00364 001160014    NENN EN                   NENN
00365 001160028   OP TRE*T T                 OPTRE*T
00366 001170010    GI N                      GI
00367 001170014    WUESS EN                  WUESS
00368 001180005    ME>CH T                   ME>CH
00369 001190009    ME>CH T                   ME>CH
00370 001190014    FE*LL T                   FE*LL
00371 001200008    SCHAFF EN                 SCHAFF
00372 001210002    KOMM EN                   KOMM
00373 001220004   BE MIERK T                 BEMIERK
00374 001220006    HA T                      HA
00375 001220023   BE TRAFF ENE               BETRAFF
00376 001220031    GEFALL                    GEFALL
00377 001220032    SIN
00378 001220038  FORT ZE KOMM EN             FORTKOMM
00379 001220045    MISS EN                   MISS
00380 001220047    SCHAFF EN                 SCHAFF
00381 001230007    AS
00382 001230013  E*M GE SCHLO EN             E*MSCHLO
00383 001230018    GESI N                    GESI
00384 001230019    HU N                      HU
00385 001230033   BE STAN EN                 BESTAN
00386 001230034    HUE T                     HUE
00387 001230039    SCHAAF EN                 SCHAAF
00388 001230049    HAL EN                    HAL
00389 001230053  OF ZE SE>CHER EN            OFSE>CHER
00390 001230063   ER HAL EN                  ERHAL
```

```
00391 001240014    GE KE*NNEG T                KE*NNEG
00392 001240015     KRUT EN                    KRUT
00393 001240025    GE SCHLO EN                 SCHLO
00394 001240026     HU N                       HU
00395 001240028     KONN TEN                   KONN
00396 001240043   AN UECHT HUEL EN             ANUECHTHUEL
00397 001250002    VER SCHIDD ENE              VERSCHIDD
00398 001250010   SOU GE NANN TEN              SOUNANN
00399 001250013     KANN                       KANN
00400 001250019     SCHWA*TZ EN                SCHWA*TZ
00401 001260005    GE KUCK T                   KUCK
00402 001260011     VERGLACH                   VERGLACH
00403 001260013     HUE T                      HUE
00404 001260022    GE PACK T                   PACK
00405 001270006     GI N                       GI
00406 001270015     AS
00407 001270017     KANN                       KANN
00408 001270022    GE PLANG TEN                PLANG
00409 001270032     GESI N                     GESI
00410 001270044     SIN
END OF DATA
```

.TRANSIT3 pour le néerlandais :

```
*00132
*06340
00001 000259005    LIJK EN                LIJK
00002 000250013    IMPONER EN             IMPONER
00003 000260005    GEBEUR DE              GEBEUR
00004 000260011   DOOR DRING EN           DOORDRING
00005 000260024    SLUIMER ENDE           SLUIMER
00006 000270003    WAS
00007 000270012    WERD                   WERD
00008 000270013   BE STEED                BESTEED
00009 000270027    HEBB EN                HEBB
00010 000270028  OP GE RICHT              OPRICHT
00011 000270036    ZIJN                   ZIJN
00012 000270037   BE LOON D               BELOON
00013 000280003    IS
00014 000280006   GE DRAAI D              DRAAI
00015 000290005    WORD EN                WORD
00016 000290010   UIT SPRAK EN            UITSPRAK
00017 000290016  WEER GE GEV EN           WEERGEV
00018 000290019  GE WAAR SCHUW D          GEWAARSCHUW
00019 000290020    WORD T                 WORD
00020 000300003    WORD T                 WORD
00021 000300005   DOOR DRONG EN           DOORDRONG
00022 000300007    ZIJN                   ZIJN
00023 000300016   GE WAPEN D              WAPEN
00024 000300020   DOOR GROND EN           DOORGROND
00025 000300025    STREV EN               STREV
00026 000300028   OVER HEERS EN           OVERHEERS
00027 000310004    GAA T                  GAA
00028 000310019    STAA N                 STAA
00029 000310023    LEVER EN               LEVER
00030 000320003    MEEN T                 MEEN
00031 000320018    HOUD EN                HOUD
00032 000320022    IS
00033 000320024   DOOR GROND EN           DOORGROND
00034 000320034    ZAK EN                 ZAK
00035 000320044    HEBB EN                HEBB
00036 000320046   GE ACHT                 ACHT
00037 000320047    WORD EN                WORD
00038 000320051    HEBB EN                HEBB
00039 000330005   UIT GAA NDE             UITGAA
00040 000330006    IS
00041 000330009   GE KOZ EN               KOZ
00042 000330021    BIED EN                BIED
00043 000330032   BE HANDEL EN            BEHANDEL
00044 000340003    ZIJN                   ZIJN
00045 000340005    VIND EN                VIND
00046 000340009  AF GE DRUK TE            AFDRUK
00047 000340015    ZIJN                   ZIJN
00048 000350002    WORD EN                WORD
00049 000350013   BE HANDEL D             BEHANDEL
00050 000350033    WORD T                 WORD
00051 000350034   BE SPROK EN             BESPROK
00052 000360002    DOEN EN                DOEN
00053 000360015    WORD EN                WORD
00054 000360016   BE HANDEL D             BEHANDEL
```

```
00055 000370004    KUNN EN                KUNN
00056 000370019    PASSER EN              PASSER
00057 000370025    WORD EN                WORD
00058 000370026   BE SPROK EN             BESPROK
00059 000380004    WORD EN                WORD
00060 000380014   BE SPROK EN             BESPROK
00061 000380017    ZIJN                   ZIJN
00062 000380025   VOOR ZIE N              VOORZIE
00063 000390003    ZULL EN                ZULL
00064 000390011    WILL EN                WILL
00065 000390012   VOL STAA N              VOLSTAA
00066 000400002    WILL EN                WILL
00067 000400006    LEZ EN                 LEZ
00068 000400019    WORD EN                WORD
00069 000400020   TOE GE PAS T            TOEPAS
00070 000400035    WORD T                 WORD
00071 000400036   BE SPROK EN             BESPROK
00072 000410006    KIJK T                 KIJK
00073 000420021    WORD T                 WORD
00074 000420028   AF GE SLOT EN           AFSLOT
00075 000430005    IS
00076 000430006   BE OOG D                BEOOG
00077 000430021    GEV EN                 GEV
00078 000440007    IS
00079 000440011   ONDER GE SCHIK T         ONDERSCHIK
00080 000440012   GE MAAK T                MAAK
00081 000440015    ZIJN                   ZIJN
00082 000440019   GE BRUIK T               BRUIK
00083 000440024    ZULL EN                ZULL
00084 000440025    VIND EN                VIND
00085 000450002    IS
00086 000450012    IS
00087 000450018   VER MELD                VERMELD
00088 000460006    ZOU
00089 000460009    KUNN EN                KUNN
00090 000460010    WEKK EN                WEKK
00091 000460014    WORD EN                WORD
00092 000460015   BE SPROK EN             BESPROK
00093 000460022    ZAL
00094 000460023    WORD EN                WORD
00095 000460024   TOE GE PAS T            TOEPAS
00096 000460039    WORD T                 WORD
00097 000460031    GEORGANISEER D         ORGANISEER
00098 000470009    KOM EN                 KOM
00099 000470010    WORD T                 WORD
00100 000470014   NA GE STREEF D          NASTREEF
00101 000470021    GEV EN                 GEV
00102 000470026    ZAL
00103 000470027    HELP EN                HELP
00104 000470035    VORM EN                VORM
00105 000480004    WIL
00106 000480006    ZIJN                   ZIJN
00107 000480008   UIT SPREK EN            UITSPREK
00108 000480017    ILLUSTRER EN           ILLUSTRER
00109 000480032    HEBB EN                HEBB
00110 000480033   BIJ GE STAA N           BIJSTAA
00111 000490009    WAR EN                 WAR
00112 000520007    GEBRUIK EN             GEBRUIK
00113 000520008    WORD T                 WORD
```

```
00114 000520009   OP GE WEK T                  OPWEK
00115 000520019    GE NOEM D                   NOEM
00116 000520020     WORD EN                    WORD
00117 000530004     WORD T                     WORD
00118 000530007   OM GE ZET                    OMZET
00119 000540005     WORD T                     WORD
00120 000540009    GE LEVER D                  LEVER
00121 000550004     IS
00122 000560003     WORD EN                    WORD
00123 000560009   TOE GE PAS T                 TOEPAS
00124 000560025     LEVER EN                   LEVER
00125 000560026     WORD T                     WORD
00126 000560032   AAN GE DREV EN               AANDREV
00127 000570005     IS
00128 000570012   VOORT BE WEEG T              VOORTBEWEEG
00129 000570017     GEBEUR T                   GEBEUR
00130 000570025     IS
00131 000570034   OP GE POMP T                 OPPOMP
00132 000580010     IS
00133 000580017    AAN DRIJF T                 AANDRIJF
00134 000590007     ZIJN                       ZIJN
00135 000590018     BLAZ EN                    BLAZ
00136 000600005     WORD T                     WORD
00137 000600006   OP GE WEK T                  OPWEK
00138 000600009   AAN GE DREV EN               AANDREV
00139 000620006     BENODIG DE                 BENODIG
00140 000620008     WORD T                     WORD
00141 000620011   OP GE WEK T                  OPWEK
00142 000620014    VER WARM D                  VERWARM
00143 000630013     KOM EN                     KOM
00144 000630015    BE SCHOUW EN                BESCHOUW
00145 000640011     IS
00146 000650002     KOM T                      KOM
00147 000650017     BEVAT                      BEVAT
00148 000650023     REAGEER T                  REAGEER
00149 000660002    BE HOOR T                   BEHOOR
00150 000660007     IS
00151 000660014    BE STAA T                   BESTAA
00152 000660022    OM RING D                   OMRING
00153 000660029    GE SCHREV EN                SCHREV
00154 000660036     ZIE
00155 000670002     KAN
00156 000670005   GE STIL EER D                GESTILEER
00157 000670006   TE RUG VIND EN               TERUGVIND
00158 000670017     MOET                       MOET
00159 000670025    VOOR STELL EN               VOORSTELL
00160 000680003     IS
00161 000680010     WIL
00162 000680011     ZEGG EN                    ZEGG
00163 000680024     TOON T                     TOON
00164 000680028     ZIJN                       ZIJN
00165 000680033     VORM EN                    VORM
00166 000690006     KAN
00167 000690009     WORD EN                    WORD
00168 000690010    GE SCHREV EN                SCHREV
00169 000700020     STAA N                     STAA
00170 000710004   AF GE BEELD E                AFBEELD
00171 000710008     HAL EN                     HAL
00172 000710009     KRIJG EN                   KRIJG
```

```
00173 000720001    ZOU DEN                ZOU
00174 000720006    DOE N                  DOE
00175 000720009    ZOU DEN                ZOU
00176 000720011    MERK EN                MERK
00177 000720017    HAL EN                 HAL
00178 000720032    IS
00179 000730002    ZOU
00180 000730004    BLIJK EN               BLIJK
00181 000730017    IS
00182 000730022    IS
00183 000730035   VRIJ KOM T              VRIJKOM
00184 000730039    WORD T                 WORD
00185 000730040   GE BRUIK T              BRUIK
00186 000730045    WEKK EN                WEKK
00187 000740006    IS
00188 000740018    GEBRUIK EN             GEBRUIK
00189 000740020    ZIE
00190 000770004    WEEG T                 WEEG
00191 000770012    BRENG EN               BRENG
00192 000790006   VER MOG EN              VERMOG
00193 000790010    IS
00194 000790019    DRUKK EN               DRUKK
00195 000790020    ZIJN                   ZIJN
00196 000790021   VER SCHILL ENDE         VERSCHILL
00197 000790038    WORD T                 WORD
00198 000790039   UIT GE GAA N            UITGAA
00199 000790049    KEN T                  KEN
00200 000800010   GE BRUIK T              BRUIK
00201 000800018    IS
00202 000810015   OM ZET                  OMZET
00203 000810018    DUID T                 DUID
00204 000810032    ZIJN                   ZIJN
00205 000810034    VIND T                 VIND
00206 000820014    ZAL
00207 000820020    WORD EN                WORD
00208 000820021   GE BRUIK T              BRUIK
00209 000830005    PAS T                  PAS
00210 000830016    ZAL
00211 000830017    ZIJN                   ZIJN
00212 000830020   OVER EEN KOM T          OVEREENKOM
00213 000850016    DUID EN                DUID
00214 000850017    ZAL
00215 000850033    WORD EN                WORD
00216 000850034   GE BRUIK T              BRUIK
00217 000850037    ZAL
00218 000850047    WORD EN                WORD
00219 000850048   GE NOEM D               NOEM
00220 000860002    ZULL EN                ZULL
00221 000860005    WORD EN                WORD
00222 000860006   GE BRUIK T              BRUIK
00223 000870005   BE HOOR T               BEHOOR
00224 000880011    KOM EN                 KOM
00225 000880012   GE BRUIK T              BRUIK
00226 000890003    KOM EN                 KOM
00227 000900003    ZULL EN                ZULL
00228 000900006    WORD EN                WORD
00229 000900007   GE BRUIK T              BRUIK
00230 000900025   BE SPAAR D              BESPAAR
00231 000900026    BLIJV EN               BLIJV
```

```
00232 000910003    ZIJN                    ZIJN
00233 000910012    WIL
00234 000910013    DOE N                   DOE
00235 000910014    GELOV EN                GELOV
00236 000920003    ZIT
00237 000920011    GECONCENTREER D         CONCENTREER
00238 000920025   IN NEEM T                INNEEM
00239 000930004    IS
00240 000930017   GE LAD EN                LAD
00241 000930026    ZIJN                    ZIJN
00242 000930041   TE KEN EN                TEKEN
00243 000950018  VOOR GE STEL D            VOORSTEL
00244 000970010    GEEF T                  GEEF
00245 000980007    HEBB EN                 HEBB
00246 000990003    DRAAG T                 DRAAG
00247 000990014  ON GE LAD EN               ONLAD
00248 000990015    IS
00249 001000004    TREKK EN                TREKK
00250 001000012    BLIJV EN                BLIJV
00251 001000016    VALL EN                 VALL
00252 001010002    STUIT EN                STUIT
00253 001020005    MOET EN                 MOET
00254 001020006    ZIJN                    ZIJN
00255 001020007    IS
00256 001020012    MOG EN                  MOG
00257 001020014   VER WACHT EN             VERWACHT
00258 001020023   OM RING ENDE             OMRING
00259 001020025    TRACHT EN               TRACHT
00260 001020028    VOER EN                 VOER
00261 001020042   OM RING ENDE             OMRING
00262 001020043   VOOR WERP EN             VOORWERP
00263 001020044    ZULL EN                 ZULL
00264 001020045   GE DRAG EN               DRAG
00265 001030004    LEER T                  LEER
00266 001030010   GE PLAATS T              PLAATS
00267 001030011    MOET                    MOET
00268 001030012    WORD EN                 WORD
00269 001030020    WORD EN                 WORD
00270 001030021   OP GE VAT                OPVAT
00271 001040004    ZIE N                   ZIE
00272 001040015    DRAAI EN                DRAAI
00273 001040018    UITGESMEER D            UITGESMEER
00274 001050002    ZIJN                    ZIJN
00275 001050012   GE LAD EN                LAD
00276 001050019   SAMEN BIND EN            SAMENBIND
00277 001060010   BE SPROK EN              BESPROK
00278 001060015    BLIJV EN                BLIJV
00279 001060018  ON AAN GE TAST            ONAANTAST
00280 001070002    ZULL EN                 ZULL
00281 001070007   BE KIJK EN               BEKIJK
00282 001090006    ZIJN                    ZIJN
00283 001090010    IS
00284 001100004    BLIJK T                 BLIJK
00285 001100008    ZIJN                    ZIJN
00286 001100014    DANK T                  DANK
00287 001110006   GE ZEG D                 ZEG
00288 001110007    WERD                    WERD
00289 001110008    BEVAT                   BEVAT
00290 001120001    WAS
```

```
00291 001120009     ZOU
00292 001120017     MOET EN                    MOET
00293 001120018     WEG EN                     WEG
00294 001130001     ZOU
00295 001130011    NA WEG EN                   NAWEG
00296 001130014     ZOU
00297 001130015     BLIJK EN                   BLIJK
00298 001130019     KLOP T                     KLOP
00299 001130031    VER HOUD EN                 VERHOUD
00300 001140005     IS
00301 001140011    BE STAA T                   BESTAA
00302 001140017     IS
00303 001140027     DRAAG T                    DRAAG
00304 001140035     DRAAG T                    DRAAG
00305 001150003     MOET                       MOET
00306 001150007     BEVATT EN                  BEVATT
00307 001160002     KAN
00308 001160005     WORD EN                    WORD
00309 001160006     GEKARAKTERISEER D          KARAKTERISEER
00310 001160022    AAN GEEF T                  AANGEEF
00311 001160047    GE NOEM D                   NOEM
00312 001170007     WORD T                     WORD
00313 001170012   AAN GE DUID                  AANDUID
00314 001180003     MOET                       MOET
00315 001180008     WORD EN                    WORD
00316 001180009   AAN GE BRACH T               AANBRACH
00317 001190003     HEBB EN                    HEBB
00318 001190014     HEBB EN                    HEBB
00319 001190024     BLIJK T                    BLIJK
00320 001190029     ZIJN                       ZIJN
00321 001190031     HEEF T                     HEEF
00322 001200002     BLIJK T                    BLIJK
00323 001200012     HEBB EN                    HEBB
00324 001200014     HEEF T                     HEEF
00325 001210002    VER SCHILL ENDE             VERSCHILL
00326 001210014    VER SCHILL EN               VERSCHILL
00327 001210016     NOEM T                     NOEM
00328 001220003     VOEG T                     VOEG
00329 001230006     VOEG T                     VOEG
00330 001230028    GE NOEM DE                  NOEM
00331 001240007     HEEF T                     HEEF
00332 001240013    VER WORV EN                 VERWORV
00333 001240030    GE SCHREV EN                SCHREV
00334 001240031     WORD T                     WORD
00335 001250005     ZIJN                       ZIJN
00336 001250017     KOM EN                     KOM
00337 001250025   OP GE SOM D                  OPSOM
00338 001250038    AAN TREFF EN                AANTREFF
00339 001260008     VIND EN                    VIND
00340 001260009     IS
00341 001260017    BE STAA T                   BESTAA
00342 001270010     WORD T                     WORD
00343 001270016    GE BRUIK T                  BRUIK
00344 001270020     WORD T                     WORD
00345 001270022     GEKARAKTERISEER D          KARAKTERISEER
00346 001280004     ZAL
00347 001280009    GE BRUIK T                  BRUIK
00348 001280010     WORD EN                    WORD
00349 001280014     GEEF T                     GEEF
```

```
00350 001280021    BE KEN DE                    BEKEN
00351 001290010    BE HANDEL DE                 BEHANDEL
00352 001290011    BE GRIPP EN                  BEGRIPP
00353 001290012     WORD T                      WORD
00354 001290013    ONDER STAA ND                ONDERSTAA
00355 001290021   SAMEN GE VAT                  SAMENVAT
00356 001300007     ZIJN                        ZIJN
00357 001300008   IN GE VOER D                  INVOER
00358 001300030   VER WAAR LOOS D               VERWAARLOOS
00359 001300031     IS
00360 001320003     HEEF T                      HEEF
00361 001320009     KUNN EN                     KUNN
00362 001320010    BE PAL EN                    BEPAL
00363 001320013     BLIJK T                     BLIJK
00364 001320016    IN HOUD                      INHOUD
00365 001320018    TOE NEEM T                   TOENEEM
00366 001330002     ZITT EN                     ZITT
00367 001330011    GE PAK T                     PAK
00368 001340002     HOUD T                      HOUD
00369 001350019     HEBB EN                     HEBB
00370 001350025    BE TREF T                    BETREF
00371 001350028     WERK EN                     WERK
00372 001350033    AF STOT END                  AFSTOT
00373 001350046     KOM EN                      KOM
00374 001360002     MOET                        MOET
00375 001360008     WERK EN                     WERK
00376 001370002    GE BLEK EN                   BLEK
00377 001370003     IS
00378 001370010     GAA T                       GAA
00379 001370011     WERK EN                     WERK
00380 001370017     ZIJN                        ZIJN
00381 001370022     ZULL EN                     ZULL
00382 001370028     NOEM EN                     NOEM
00383 001380003     WERK T                      WERK
00384 001380028     ZIJN                        ZIJN
00385 001390007     KON DEN                     KON
00386 001390008     SPREK EN                    SPREK
00387 001390014     IS
00388 001390019     ZOU
00389 001390020     ZIJN                        ZIJN
00390 001390024     SPLITS EN                   SPLITS
00391 001390031     KUNN EN                     KUNN
00392 001390045    VER RICHT                    VERRICHT
00393 001390046     ZOU
00394 001390047     MOET EN                     MOET
00395 001390048     WORD EN                     WORD
00396 001390053     BREK EN                     BREK
00397 001400002     IS
00398 001400011     ZAL
00399 001400012     ZIJN                        ZIJN
00400 001410012     ZITT EN                     ZITT
00401 001410023    GE PAK T                     PAK
00402 001410032     ZIJN                        ZIJN
00403 001420001     ZOU DEN                     ZOU
00404 001420005     VLIEG EN                    VLIEG
00405 001420007     ZOU
00406 001420013    VRIJ KOM EN                  VRIJKOM
00407 001420021     MOET                        MOET
00408 001420026     KOST EN                     KOST
```

```
00409 001420033   VER HINDER EN          VERHINDER
00410 001420036   DOOR BREK EN           DOORBREK
00411 001430008    IS
00412 001430012    WERK EN               WERK
00413 001430022   GE GEV EN              GEV
00414 001430026    WIL
00415 001430028    ZEGG EN               ZEGG
00416 001440001   GE GEV EN              GEV
00417 001440012    KAN
00418 001440017   HER LEID EN            HERLEID
00419 001440026    IS
00420 001440032    ZULL EN               ZULL
00421 001440033    GEBRUIK EN            GEBRUIK
00422 001450005    IS
00423 001460003    STEL T                STEL
00424 001460008   VOOR KOM ENDE          VOORKOM
00425 001460012    BEGINN END            BEGINN
00426 001460017    EINDIG END            EINDIG
00427 001470008    VRAAG T               VRAAG
00428 001470009    IS
00429 001470014   UIT GE DRUK T          UITDRUK
00430 001470015    IS
00431 001480003    IS
00432 001490010   VRIJ KOM T             VRIJKOM
00433 001490023    VOLG ENDE             VOLG
00434 001490025    IS
00435 001490031   AF HANG T              AFHANG
00436 001500002    IS
00437 001510001    GAA N                 GAA
00438 001510009    PLAKK EN              PLAKK
00439 001510012    ZAL
00440 001510017   TOE NEM EN             TOENEM
00441 001510026    PLAATS EN             PLAATS
00442 001510031   VER BIND EN            VERBIND
00443 001520006    ZIE N                 ZIE
00444 001520010    BLIJK T               BLIJK
00445 001520017   AF NEEM T              AFNEEM
00446 001520028    KRIJG EN              KRIJG
00447 001540012   UIT GE ZET             UITZET
00448 001550011    ILLUSTRER EN          ILLUSTRER
00449 001550012    ZIJN                  ZIJN
00450 001550014   GE BOG EN              BOG
00451 001550016   IN GE TEKEN D          INTEKEN
00452 001550023   AF GE BEELD E          AFBEELD
00453 001550025    WEER GEV EN           WEERGEV
00454 001550032    ONT STAA N            ONTSTAA
00455 001560009    ZIJN                  ZIJN
00456 001560010   AAN GE GEV EN          AANGEV
00457 001570008    WORD T                WORD
00458 001570011    BE REIK T             BEREIK
00459 001570020    IS
00460 001580004    IS
00461 001580012    WORD T                WORD
00462 001580020   TOE NEEM T             TOENEEM
00463 001590002    WORD T                WORD
00464 001590021    ZAL
00465 001590022    KOM EN                KOM
00466 001590033   BE HOUD EN             BEHOUD
00467 001600003    HEET                  HEET
```

```
00468 001600021    VIND EN                  VIND
00469 001610016    KWAM EN                  KWAM
00470 001610018    KAN
00471 001610021    ZIJN                     ZIJN
00472 001610022   GE WEK T                  WEK
00473 001610035    MOET EN                  MOET
00474 001610036    ZIJN                     ZIJN
00475 001620002    IS
00476 001620003   GE BLEK EN                BLEK
00477 001620009    IS
00478 001620013    IS
00479 001620026    ZAL
00480 001620027    WORD EN                  WORD
00481 001620028  IN GE GAA N                INGAA
00482 001630004    LAAT                     LAAT
00483 001630005    ZIE N                    ZIE
00484 001630006    KOM T                    KOM
00485 001630011    ZIJN                     ZIJN
00486 001630012    RECHT                    RECHT
00487 001640009    GAA T                    GAA
00488 001640010    SPEL EN                  SPEL
00489 001640011    ZIE T                    ZIE
00490 001640014   OP TRED EN                OPTRED
00491 001650008    ZIJN                     ZIJN
00492 001660008    NOEM DEN                 NOEM
00493 001680008    ZOU DEN                  ZOU
00494 001680011    KUNN EN                  KUNN
00495 001680012    SCHIJN EN                SCHIJN
00496 001680017    ZOU DEN                  ZOU
00497 001680018    MOET EN                  MOET
00498 001680019   ONT LEN EN                ONTLEN
00499 001690004    GEBEUR T                 GEBEUR
00500 001690005    IS
00501 001690009   VER SCHILL ENDE           VERSCHILL
00502 001690011    WORD EN                  WORD
00503 001690012   OM GE ZET                 OMZET
00504 001700005    BLIJK T                  BLIJK
00505 001700006    HEBB EN                  HEBB
00506 001700013    KOM T                    KOM
00507 001710008    GAA T                    GAA
00508 001710024   VRIJ KOM T                VRIJKOM
00509 001720005    ZULL EN                  ZULL
00510 001720008    WORD EN                  WORD
00511 001720009   BE SPROK EN               BESPROK
00512 001720017    MAK EN                   MAK
00513 001730010   GE BRUIK T                BRUIK
00514 001730021    ZULL EN                  ZULL
00515 001730022    KRIJG EN                 KRIJG
00516 001730024    HANG EN                  HANG
00517 001730039   AF NEEM T                 AFNEEM
00518 001740007    WINN EN                  WINN
00519 001740008    MOET                     MOET
00520 001740013    DOE N                    DOE
00521 001740014  UIT EEN VALL EN            UITEENVALL
00522 001750002    WERD                     WERD
00523 001750015    ZIJN                     ZIJN
00524 001750019    HEBB EN                  HEBB
00525 001760003    GAA T                    GAA
00526 001760013    WORD                     WORD
```

```
00527 001760014   GE GEV EN                GEV
00528 001760020    STELL EN                STELL
00529 001770007   BINNEN DRING T           BINNENDRING
00530 001770009   ONT STAA T               ONTSTAA
00531 001770022    ZIE
00532 001780009    IS
00533 001780010  VRIJ GE KOM EN             VRIJKOM
00534 001780012    BEVIND T                BEVIND
00535 001780019    STAA T                  STAA
00536 001790005    KAN
00537 001790008    ZIJN                    ZIJN
00538 001790012   KWIJT RAK EN             KWIJTRAK
00539 001800003    IS
00540 001810007   GE VALL EN               VALL
00541 001810009    GEBEUR T                GEBEUR
00542 001810013    REK T                   REK
00543 001810023   GE GEV EN                GEV
00544 001810045   IN SNOER T               INSNOER
00545 001810058  UIT EEN VLIEG T           UITEENVLIEG
00546 001810065   VRIJ KOM EN              VRIJKOM
00547 001830009   ON STAA T                ONSTAA
00548 001830015  AAN GE SLAG EN            AANSLAG
00549 001840001    LET
00550 001840012    IS
00551 001850003    STELL EN                STELL
00552 001860003    ZIJN                    ZIJN
00553 001860011   VER DEEL D               VERDEEL
00554 001860014    KRIJG T                 KRIJG
00555 001860029    HEEF T                  HEEF
00556 001860030   GE KREG EN               KREG
00557 001860038    IS
00558 001860043   VRIJ KOM EN              VRIJKOM
00559 001880002  AAN GE SLAG EN            AANSLAG
00560 001880007    VAL T                   VAL
00561 001880015   UIT ZEND EN              UITZEND
00562 001890007    IS
00563 001890014    RESULTER END            RESULTER
00564 001900002   BE SCHOUW T              BESCHOUW
00565 001900009   PLAATS VIND T            PLAATSVIND
00566 001900012    BLIJK T                 BLIJK
00567 001900021    KOM EN                  KOM
00568 001910001    KWAM EN                 KWAM
00569 001910008    WAS
00570 001910020    ZOU
00571 001910021    VIND EN                 VIND
00572 001920006    OPEN T                  OPEN
00573 001920024    SPLIJT EN               SPLIJT
00574 001930001    ZIJN                    ZIJN
00575 001930011   VER LOOP T               VERLOOP
00576 001930017    IS
00577 001940003    HANDEL T                HANDEL
00578 001940017    HEEF T                  HEEF
00579 001950012   VER LOP EN               VERLOP
00580 001950018    NOEM T                  NOEM
00581 001950029    LAAT                    LAAT
00582 001950030   VER LOP EN               VERLOP
00583 001960005    WORD T                  WORD
00584 001960017   BE DOEL D                BEDOEL
00585 001970005    WORD EN                 WORD
```

```
00586 001970006    GE BOUW D                BOUW
00587 001970014    VRIJ KOM T               VRIJKOM
00588 001970018     WORD T                  WORD
00589 001970019    GE BRUIK T               BRUIK
00590 001970029     WEKK EN                 WEKK
00591 001980004    ONT STAA N               ONTSTAA
00592 001990008    VRIJ KOM T               VRIJKOM
00593 001990009     MOET                    MOET
00594 001990016    BE DRAG EN               BEDRAG
00595 001990019   OVER EEN KOM T            OVEREENKOM
00596 002000003     KOM T                   KOM
00597 002000022    WEG SCHIET EN            WEGSCHIET
00598 002010003     HEBB EN                 HEBB
00599 002010009     VOER EN                 VOER
00600 002020007     WORD T                  WORD
00601 002020008   OM GE ZET                 OMZET
00602 002020009     ZAL
00603 002020012     VOLG ENDE               VOLG
00604 002020014     WORD EN                 WORD
00605 002020015    BE SPROK EN              BESPROK
00606 002040008     IS
00607 002040010    GE ZORG D                ZORG
00608 002040025     ZIJN                    ZIJN
00609 002050001     ZOU
00610 002050017   BIJ EEN VOEG EN           BIJEENVOEG
00611 002050019     WEG EN                  WEG
00612 002050022     ZOU
00613 002050027     BLIJK EN                BLIJK
00614 002050029     ZIJN                    ZIJN
00615 002060004     IS
00616 002060011     KUNN EN                 KUNN
00617 002060012    OVER GAA N               OVERGAA
00618 002070004     KOM T                   KOM
00619 002070011   VRIJ GE KOM EN            VRIJKOM
00620 002080008     IS
00621 002080023     LEV EN                  LEV
00622 002080026    VER SCHILL END           VERSCHILL
00623 002080027     WORD EN                 WORD
00624 002080028     ERVAR EN                ERVAR
00625 002090002    BE DENK E                BEDENK
00626 002090013     LEV EN                  LEV
00627 002090014    OM GAA N                 OMGAA
00628 002090015     CORRESPONDER EN         CORRESPONDER
00629 002100003     KAN
00630 002100014    UIT REKEN EN             UITREKEN
00631 002100017     ZAL
00632 002100018    OP TRED EN               OPTRED
00633 002110005     ZULL EN                 ZULL
00634 002110010    BE MERK EN               BEMERK
00635 002110016     IS
00636 002120002     VIND EN                 VIND
00637 002120021     ZIJN                    ZIJN
00638 002120026     IS
00639 002120027   VOOR GE SPIEGEL D         VOORSPIEGEL
00640 002130003     BEGINN EN               BEGINN
00641 002130004     WEEG T                  WEEG
00642 002130015     IS
00643 002140003     WEEG T                  WEEG
00644 002150003     IS
```

```
00645 002150012     ZIJN                    ZIJN
00646 002150020   AF GE LEID                AFLEID
00647 002160003     VOLG ENDE               VOLG
00648 002160005     ZULL EN                 ZULL
00649 002160010    NEER SCHRIJV EN          NEERSCHRIJV
00650 002160022     ZULL EN                 ZULL
00651 002160023     KLOPP EN                KLOPP
00652 002170006     ZULL EN                 ZULL
00653 002170014     ZIJN                    ZIJN
00654 002170018     IS
00655 002170025    VER LOP ENDE             VERLOP
00656 002170027    VRIJ KOM T               VRIJKOM
00657 002170032     MOET                    MOET
00658 002170033    TOE VOEG EN              TOEVOEG
00659 002170038     DOE N                   DOE
00660 002170039    VER LOP EN               VERLOP
00661 002190010     IS
00662 002200007     LAAT                    LAAT
00663 002200015     ZIE N                   ZIE
00664 002200022     GEPRODUCEER D           PRODUCEER
00665 002200023    VER MOG EN               VERMOG
00666 002200030     WORD T                  WORD
00667 002200031   AF GE VOER D              AFVOER
00668 002200046     TRED ENDE               TRED
00669 002200048     GECONDENSEER D          CONDENSEER
00670 002200049     WORD T                  WORD
00671 002200060    UIT KOM T                UITKOM
00672 002200069     WORD T                  WORD
00673 002200070   AAN GE DUID               AANDUID
00674 002210007     TOON T                  TOON
00675 002210032     WORD T                  WORD
00676 002210033   OP GE WEK T               OPWEK
00677 002220004     BEVIND T                BEVIND
00678 002220010     WORD T                  WORD
00679 002220014   AAN GE DUID               AANDUID
00680 002230002     ZULL EN                 ZULL
00681 002230004     TRACHT EN               TRACHT
00682 002230010    AF SPEEL T               AFSPEEL
00683 002230012    BE SCHRIJV EN            BESCHRIJV
00684 002240002     ZAL
00685 002240004     WORD EN                 WORD
00686 002240005    GE MAAK T                MAAK
00687 002240017    TOE NEM END              TOENEM
00688 002240024     TON EN                  TON
READY
```

.TRANSIT3 pour l'allemand :

L'analyse est complète et les résultats se lisent de la façon suivante :

[_____|____] [VERBE DECOUPE] [_|___] [BASE]

1 2 3 4 5 6

1 : Nombre de 5 chiffres : numéro de phrase

2 : Nombre de 4 chiffres : numéro d'ordre du mot dans la phrase

3 : Verbe découpé en préverbe(s) / racine / désinence. Le "zu-" de l'infinitif est mis entre parenthèses comme le "ge-" ambigu (préverbe-morphème du participe passé).

4 : Nombre à 1 chiffre : type de verbe
- 1 verbe régulier
- 2 verbe irrégulier
- 3 auxiliaire (haben, sein, werden)
- 4 prétérito-présent
- 5 verbe d'emprunt

5 : Nombre de 3 chiffres :
- 1 infinitif (pur)
- 2 infinitif (avec morphème "zu-")
- 3 indicatif présent
- 4 prétérit
- 5 participe présent décliné
- 6 participe présent non décliné
- 7 participe passé décliné
- 8 participe passé non décliné
- A subjonctif

6 : La base est construite en associant la partie préverbale au radical de l'infinitif.

Le code peut être complété facilement. Les marques retenues sont cependant suffisantes pour le traitement des documents techniques et scientifiques que nous étudions.

```
000020004 WIRD                    3300 WERD
000020009 FORDER N                1130 FORDER
000020016 HAT                     3300 HAB
000020021 EMITTIER T              5300 EMITTIER
000020025 VER URSACH T            1300 VERURSACH
000020029 INSTALLIER EN           5130 INSTALLIER
000020030 IST                     3300 SEIN
000030003 VER SPRECH ENDER        2500 VERSPRECH
000030005 IST                     3300 SEIN
000040003 WANDEL T                1300 WANDEL
000050003 ER FAND                 2400 ERFIND
000050017 DAUER TE                1400 DAUER
000050025 KAM                     2400 KOMM
000060002 VER SORG TEN            1470 VERSORG
000060010 FAND EN                 2400 FIND
```

```
000070002 GIB T
000070006 VER BESSER TEN
000070014 SCHEIN T
000070017 SEI
000070020 ER REICH T
000070033 ER WART EN
000070034 KANN
000080007 BE STEH T
000080031 GE TRENN T
000080032 SIND
000090003 KO*NN EN
000090009 GE LAD ENE
000090016 TRANSPORTIER T
000090017 WERD EN
000090023 GE LAD ENEN
000090034 SIND
000100007 WIRD
000100010 ZU GE FU*HR T
000100026 VER SORG T
000110004 BE WIRK T
000120006 SIND
000120012 BE STEH T
000120014 KO*NN EN
000120022 WANDER N
000120040 FLIES* ENDEN
000120047 VEREINIG EN
000120052 VER LA*S* T
000130003 VER BRENN T
000130013 SETZ T
000130016 FREI WERD ENDE
000130033 VER WEND ET
000130049 TREIB EN
000130056 ER ZEUG EN
000130063 BRING EN
000130067 AN TREIB EN
000130068 KANN
000140005 HA*NG T
000140016 ARBEIT ET
000140023 BE STIMM T
000140032 GELANG EN
000140033 MUS*
000150003 TRANSPORTIER EN
000150012 WANDER N
000160005 BRAUCH EN
000160020 TRANSPORTIER EN
000160022 VER WEND ET
000170007 ER ZEUG EN
000170008 KANN
000170010 HA*NG T
000170025 GEWINN T
000180006 BE TRIEB ENE
000180008 IST
000180025 LIEFER N
000190002 ER HA*LT
000200013 GE STELL TEN
000200016 ER GIB T
000210004 ER HA*LT
000210018 ENT HALT EN
000210025 TAUCH T
000210037 UM SPU*L T

2300 GEB
1470 VERBESSER
2300 SCHEIN
3A00 SEIN
1380 ERREICH
1130 ERWART
4300 KO*NN
2300 BESTEH
1800 TRENN
3300 SEIN
4138 KO*NN
2700 LAD
5380 TRANSPORTIER
3130 WERD
2700 LAD
3300 SEIN
3300 WERD
1800 ZUFU*HR
1380 VERSORG
1380 BEWIRK
3300 SEIN
2300 BESTEH
4138 KO*NN
1130 WANDER
2500 FLIES*
1130 VEREINIG
2300 VERLASS
2300 VERBRENN
1300 SETZ
3500 FREIWERD
1388 VERWEND
2130 TREIB
1130 ERZEUG
7130 BRING
2130 ANTREIB
4300 KO*NN
2300 HA*NG
1300 ARBEIT
1380 BESTIMM
1130 GELANG
4300 MU*SS
5130 TRANSPORTIER
1130 WANDER
1130 BRAUCH
5130 TRANSPORTIER
1380 VERWEND
1130 ERZEUG
4300 KO*NN
2300 HA*NG
2300 GEWINN
2700 BETREIB
3300 SEIN
1130 LIEFER
2300 ERHALT
1700 STELL
2300 ERGEB
2300 ERHALT
2138 ENTHALT
1300 TAUCH
1300 UNSPU*L
```

```
000220003 WIRK T                          1300 WIRK
000220017 ER ZEUG T                       1380 ERZEUG
000220023 GE ZEIG TEN                     1700 ZEIG
000230002 KANN                            4300 KO*NN
000230005 MESS EN                         2130 MESS
000230017 VER BIND ET                     2300 VERBIND
000240002 EIGN ET                         1300 EIGN
000240016 IST                             3300 SEIN
000240021 IST                             3300 SEIN
000240029 LASS EN                         2130 LASS
000240037 ZU SAMMEN FASS EN               1130 ZUSAMMENFASS
000250002 BAU T                           1300 BAU
000250022 GESTALT ETE                     1470 GESTALT
000250027 IMPRA*GNIER TE                  5470 IMPRA*GNIER
000250029 PACK T                          1300 PACK
000260004 KANN                            4300 KO*NN
000260009 U*BER EIN ANDER STAPEL N        1130 U*BEREINANDERSTAPEL
000270008 LIEFER T                        1300 LIEFER
000270010 ER GIB T                        2300 ERGEB
000270024 MULTIPLIZIER T                  5380 MULTIPLIZIER
000280004 GEHO*R EN                       1130 GEHO*R
000290007 BE ZEICHN ET                    1380 BEZEICHN
000290009 HAT                             3300 HAB
000290027 ER ZEUG EN                      1130 ERZEUG
000290039 ARBEIT EN                       1130 ARBEIT
000290040 KO*NN EN                        4138 KO*NN
000290045 WANDEL T                        1300 WANDEL
000290050 GE LIEFER TE                    1700 LIEFER
000290061 ZU GE FU*HR T                   1800 ZUFU*HR
000290062 WERD EN                         3130 WERD
000290063 KANN                            4300 KO*NN
000300012 AN GE LIEFER TEN                1700 ANLIEFER
000300014 ENT HALT ENE                    2700 ENTHALT
000300029 GE STELL T                      1800 STELL
000300030 WIRD                            3300 WERD
000300032 ER GIB T                        2300 ERGEB
000300056 GE LIEFER TE                    1700 LIEFER
000300058 IST                             3300 SEIN
000310009 BE STEH T                       2300 BESTEH
000320003 BRAUCH T                        1300 BRAUCH
000320014 AUF BEREIT ET                   1380 AUFBEREIT
000320025 SIND                            3300 SEIN
000330004 VER FOLG EN                     1130 VERFOLG
000330018 STEIGER N                       1130 STEIGER
000330023 SENK EN                         1130 SENK
000340002 UNTER SCHEID EN                 2130 UNTERSCHEID
000350008 SIND                            3300 SEIN
000350018 TRIFF T                         2300 TREFF
000350027 UM GE KEHR T                    1800 UMKEHR
000360002 KANN                            4300 KO*NN
000360015 ARBEIT EN                       1130 ARBEIT
000370004 HAT                             3300 HAB
000370014 GREIF T                         2300 GREIF
000380008 BRAUCH T                        1300 BRAUCH
000380023 BE STEH ENDEN                   2500 BESTEH
000390005 LEG T                           1300 LEG
000390019 MUS*                            4300 MU*SS
000390025 FREI HALT EN                    2130 FREIHALT
000390034 BILD ET                         1300 BILD
000390042 VER RINGER T                    1380 VERRINGER
```

```
000400016 HAB EN                          3130 HAB
000400020 BE WA*HR T                      1380 BEWA*HR
000400026 SCHEITER T                      1300 SCHEITER
000410011 HA*NG EN                        2130 HA*NG
000410021 HAT                             3300 HAB
000420002 MUS*                            4300 MU*SS
000420008 BE TREIB EN                     2130 BETREIB
000420015 VER WEND ET                     1380 VERWEND
000420019 NIMM T                          2300 NEHM
000420024 ENT HALT ENE                    2700 ENTHALT
000420030 UN VER A*NDER T                 1800 VERA*NDER
000420031 VER LA*S* T                     2300 VERLASS
000430004 ER REICH T                      1380 ERREICH
000430020 AN GE SCHLOSS ENEN              2700 ANSCHLIES*
000430022 HAB EN                          3130 HAB
000430023 MUS*                            4300 MU*SS
000440004 INTERESSIER T                   5380 INTERESSIER
000440016 ARBEIT EN                       1130 ARBEIT
000440018 BE SCHA*FTIG T                  1380 BESCHA*FTIG
000440029 UNTER SUCH T                    1300 UNTERSUCH
000440035 TRANSPORTIER EN                 5130 TRANSPORTIER
000440042 VERLANG EN                      1130 VERLANG
000440045 SIND                            3300 SEIN
000450005 LIEG EN                         2130 LIEG
000450024 VER WEND EN                     1130 VERWEND
000450025 LA*S* T                         2300 LASS
000450031 ZU SAMMEN (ZU) SETZ EN          1200 ZUSAMMENSETZ
000460003 BLEIB T                         2300 BLEIB
000460012 UN VER A*NDER T                 1800 VERA*NDER
000460023 ERMO*GLICH T                    1380 ERMO*GLICH
000460028 EIN SETZ T                      1300 EINSETZ
000460036 AUS (ZU) GLEICH EN              2200 AUSGLEICH
000470002 ER KENN T                       2300 ERKENN
000470005 FOLG ENDEM                      1500 FOLG
000470016 BE HEIZ TES                     1700 BEHEIZ
000470025 GEWONN ENE                      2700 GEWINN
000470029 TREIB T                         2300 TREIB
000470037 DIEN T                          1300 DIEN
000470039 BRAUCH T                        1390 BRAUCH
000470051 ER ZEUG EN                      1130 ERZEUG
000470058 ARBEIT ET                       1300 ARBEIT
000480001 WIRD                            3300 WERD
000480014 GE NUTZ T                       1800 NUTZ
000480017 VER BRAUCH T                    1380 VERBRAUCH
000480027 LIEFER N                        1130 LIEFER
000490003 VER BRAUCH T                    1380 VERBRAUCH
000500002 IST                             3300 SEIN
000500011 AUS (ZU) LEG EN                 1200 AUSLEG
000500019 BE FRIEDIG T                    1380 BEFRIEDIG
000500026 LA*UF T                         2300 LAUF
000500034 KOPPEL N                        1130 KOPPEL
000500038 BE TRIEB EN                     2430 BETREIB
000500039 WIRD                            3300 WERD
000500044 AUF KOMM T                      2300 AUFKOMM
000510004 ER ZEUG T                       1380 ERZEUG
000510012 DIEN T                          1300 DIEN
```

```
000520008 SIND                    3300 SEIN
000520016 LIEG T                  2300 LIEG
000520028 IST                     3300 SEIN
000520035 ENT FERN T              1380 ENTFERN
000520036 WERD EN                 3130 WERD
000520037 MU*SS EN                4136 MU*SS
000530003 SOLL TE                 4400 SOLL
000530006 VER URSACH EN           1130 VERURSACH
000530017 BRAUCH EN               1130 BRAUCH
000540002 MU*S* TE                4A00 MU*SS
000540005 SEIN                    3100 SEIN
000540015 INSTALLIER EN           5130 INSTALLIER
000540031 VER BUND ENEN           2700 VERBIND
000540033 VER MEID ET             2300 VERMEID
000550007 ZU SAMMEN SETZ EN       1130 ZUSAMMENSETZ
000550008 LASS EN                 2130 LASS
000550010 KANN                    4300 KO*NN
000550019 PRODUZIER EN            5130 PRODUZIER
000560006 KONSTRUIER TEN          5470 KONSTRUIER
000560008 KANN                    4300 KO*NN
000560015 RICHT EN                1130 RICHT
000560019 WACHS EN                2130 WACHS
000570002 VERMINDER T             1380 VERMINDER
000580003 SOLL TE                 4400 SOLL
000580007 SEIN                    3100 SEIN
000580010 AB GE STUF TES          1700 ABSTUF
000580014 AUF (ZU) BAU EN         1200 AUFBAU
000580028 KO*NN TEN               4A00 KO*NN
000580034 STEH EN                 2130 STEH
000580038 ARBEIT EN               1130 ARBEIT
000580043 ER ZEUG EN              1130 ERZEUG
000590002 WU*RD EN                3A00 WERD
000590009 VER BRAUCH EN           1130 VERBRAUCH
000590015 BE NO*TIG T             1380 BENO*TIG
000590016 WIRD                    3300 WERD
000590021 SOLL TE                 4400 SOLL
000590025 BE TRAG EN              2138 BETRAG
000600010 WA*R EN                 3A00 SEIN
000600017 INSTALLIER EN           5130 INSTALLIER
000600023 AUF (ZU) FANG EN        2200 AUFFANG
000610006 WA*R E                  3A00 SEIN
000610015 VER WEND EN             1130 VERWEND
000610017 LIES* EN                2400 LASS
000610024 BE ZOG EN               2480 BEZIEH
000610026 VER BRAUCH TEN          1470 VERBRAUCH
000610029 ER REICH EN             1130 ERREICH
000620005 WIRD                    3300 WERD
000620010 KOMBINIER EN            5130 KOMBINIER
000620022 KOMM EN                 2130 KOMM
000620030 IST                     3300 SEIN
000630001 BE ZOG EN               2480 BEZIEH
000630006 VER BRAUCH TEN          1470 VERBRAUCH
000630008 SIND                    3300 SEIN
000630015 ER WART EN              1130 ERWART
000640006 ARBEIT ENDE             1500 ARBEIT
000640008 IST                     3300 SEIN
000640011 FORT GE SCHRITT EN      2800 FORTSCHREIT
```

```
000650002 BE STEH T                    2300 BESTEH
000650010 KONZENTRIER TER              5700 KONZENTRIER
000650012 GE TRA*NK TEN                1700 TRA*NK
000650020 LIEG T                       2300 LIEG
000660002 ENT HALT EN                  2130 ENTHALT
000670003 ARBEIT ET                    1300 ARBEIT
000670011 ER ZEUG T                    1380 ERZEUG
000670018 HAT                          3300 HAB
000680002 SCHA*TZ T                    1300 SCHA*TZ
000680011 BE STEH EN                   2130 BESTEH
000680022 PRODUZIER T                  5380 PRODUZIER
000680023 WERD EN                      3130 WERD
000680024 KO*NN EN                     4130 KO*NN
000680037 BE LA*UF T                   2300 BELAUF
000690003 WA*R E                       3A00 SEIN
000700005 HAB EN                       3130 HAB
000700011 ER REICH T                   1380 ERREICH
000700022 GEH ENDE                     2500 GEH
000700027 STEH T                       2300 STEH
000710012 ARBEIT EN                    1130 ARBEIT
000710014 IST                          3300 SEIN
000720005 GE SCHMOLZ ENEM              2700 SCHMELZ
000720010 LIEG T                       2300 LIEG
000730003 BE TRA*G T                   2300 BETRAG
000730012 VER LAUF EN                  2130 VERLAUF
000730025 BRAUCH T                     1300 BRAUCH
000740004 BILD ET                      1300 BILD
000740017 WIRK T                       1300 WIRK
000740022 UN VER A*NDER T              1800 VERA*NDER
000740023 BLEIB T                      2300 BLEIB
000750002 ER ZEUG EN                   1130 ERZEUG
000750009 HAB EN                       3130 HAB
000760009 SIND                         3300 SEIN
000770004 HAT                          3300 HAB
000770022 BE STEH ENDER                2500 BESTEH
000770024 ARBEIT ET                    1300 ARBEIT
000780003 ERMUTIG ENDEN                1500 ERMUTIG
000780005 GIB T                        2300 GEB
000790002 BE STEH EN                   2130 BESTEH
000790014 BE GRENZ EN                  1130 BEGRENZ
000800003 KOMM EN                      2130 KOMM
000810016 SIND                         3300 SEIN
000810019 ENT WICKEL T                 1380 ENTWICKEL
000810030 EIN GE SETZ T                1800 EINSETZ
000810031 WERD EN                      3130 WERD
000810032 KO*NN EN                     4130 KO*NN
000820003 KO*NN EN                     4130 KO*NN
000820009 BE ZEICHN ETE                1470 BEZEICHN
000820017 SIED ENDE                    2500 SIED
000820025 VER ARBEIT EN                1130 VERARBEIT
000830002 BE MU*H T                    1380 BEMU*H
000830010 ENT WICKEL N                 1130 ENTWICKEL
000830023 BE TRIEB EN                  2480 BETREIB
000830024 WERD EN                      3130 WERD
000830025 KO*NN EN                     4130 KO*NN
000840005 (GE)BOT ENEN                 2700 (GE)BIET
000840007 WERD EN                      3130 WERD
000840010 NUTZ EN                      1130 NUTZ
000840011 LASS EN                      2130 LASS
000840017 PRODUZIER T                  5380 PRODUZIER
000840018 WERD EN                      3130 WERD
```

```
000850002 LIEG T                    2300 LIEG
000850005 ENT SCHEID ENDE           2500 ENTSCHEID
000850012 WERD EN                   3130 WERD
000850015 SEIN                      3100
000850020 WIRD                      3300 WERD
000850025 SINK EN                   2130 SINK
000850031 WA*CHS T                  2300 WACHS
000860016 GIB T                     2300 GEB
000860020 UNTER STU*TZ EN           1130 UNTERSTU*TZ
000860022 WERD EN                   3130 WERD
000860027 SEIN                      3100 SEIN
000860031 EIN (ZU) LEIT EN          1200 EINLEIT
000860033 FORT (ZU) SETZ EN         1200 FORTSETZ
000860039 LIEG T                    2300 LIEG
000860044 GESTATT ET                1300 GESTATT
000860048 SPAR EN                   1130 SPAR
000860055 VERMINDER N               1130 VERMINDER
000870004 GIB T                     2300 GEB
000870014 BE STEH T                 2300 BESTEH
000870023 ENT WICKEL N              1130 ENTWICKEL
000870032 WIRD                      3300 WERD
000880004 LA*UF T                   2300 LAUF
000890002 BE STEH T                 2300 BESTEH
000890006 HAT                       3300 HAB
000890013 BE TRIEB ENEN             2700 BETREIB
000890015 AN GE NOMM EN             2800 ANNEHM
000900004 IST                       3300 SEIN
000900016 INSTALLIER T              5380 INSTALLIER
000900017 WERD EN                   3130 WERD
000900018 KO*NN EN                  4130 KO*NN
000910010 VER WEND ET               1300 VERWEND
000910011 WIRD                      3300 WERD
000910013 IST                       3300 SEIN
000920004 WURD EN                   3400 WERD
000920012 AUSPROBIER T              5300 AUSPROBIER
000930004 GEWONN ENEN               2700 GEWINN
000930006 BAU TE                    1400 BAU
000930020 ER PROB T                 1300 ERPROB
000930021 WERD EN                   3130 WERD
000930027 KOMM EN                   2130 KOMM
000930028 SOLL                      4300 SOLL
000940003 HAT                       3300 HAB
000940011 AUS GE GEB EN             2800 AUSGEB
000950004 WURD E                    3400 WERD
000950020 GE RUF EN                 2800 RUF
000960002 BE SCHA*FTIG T            1300 BESCHA*FTIG
000960010 BE STEH EN                2130 BESTEH
000970004 ZEIG TE                   1400 ZEIG
000970018 BE TRIEB ENES             2700 BETREIB
000970020 GE EIGN ET                1800 EIGN
000970021 IST                       3300 SEIN
000970027 ARBEIT EN                 1130 ARBEIT
000970038 GENU*G T                  1380 GENU*G
000980003 WILL                      4300 WOLL
000980021 STEH EN                   2130 STEH
000980022 KO*NN TE                  4A00 KO*NN
000980026 ER RICHT EN               1130 ERRICHT
000980035 SCHA*TZ T                 1300 SCHA*TZ
```

```
000990011 GE TRAG EN                2800 TRAG
000990012 WURD E                    3400 WERD
000990022 BE TEILIG T               1380 BETEILIG
000990024 WIDM ET                   1300 WIDM
000990036 ARBEIT EN                 1130 ARBEIT
001000005 BE STEH ENDES             2500 BESTEH
001000008 SOLL                      4300 SOLL
001000013 VER WEND EN               1130 VERWEND
001000014 KO*NN EN                  4130 KO*NN
001000018 WIRD                      3300 WERD
001000022 BE TRAG EN                2138 BETRAG
001000026 RECHN ET                  1300 RECHN
001010006 WIRD                      3300 WERD
001010012 GE ARBEIT ET              1800 ARBEIT
001010025 KOMM EN                   2130 KOMM
001020013 AUTOMATISIER TE           5470 AUTOMATISIER
001020026 IMPLANTIER T              5320 IMPLANTIER
001020027 WERD EN                   3130 WERD
001020028 KO*NN EN                  4130 KO*NN
001020045 ARBEIT EN                 1130 ARBEIT
001020047 STEH EN                   2130 STEH
001030011 SOLL                      4300 SOLL
001030022 INSTALLIER T              5380 INSTALLIER
001030023 WERD EN                   3130 WERD
001040005 IST                       3300 SEIN
001040015 ER ZEUG T                 1380 ERZEUG
001040019 LEIST ET                  1300 LEIST
001050003 ARBEIT EN                 1130 ARBEIT
001050009 VER WEND EN               1130 VERWEND
001050021 BE ZEICHN ETEN            1470 BEZEICHN
001050029 SIED ENDEN                2500 SIED
001050031 ER ZEUG T                 1380 ERZEUG
001050032 WIRD                      3300 WERD
001060003 DIEN T                    1300 DIEN
001070006 ZEIG T                    1300 ZEIG
001080003 WANDEL N                  1130 WANDEL
001090002 EMITTIER EN               5130 EMITTIER
001090008 HAB EN                    3130 HAB
001090014 NUTZ T                    1300 NUTZ
001100002 WIRD                      3300 WERD
001100003 UNTER SUCH T              1300 UNTERSUCH
001100012 ARBEIT EN                 1130 ARBEIT
001120003 DIEN T                    1300 DIEN
001120009 ER ZEUG TES               1700 ERZEUG
001130004 WERD EN                   3130 WERD
001130012 GE LAD ENE                2700 LAD
001130019 GE LAD ENE                2700 LAD
001130024 AUF GE SPALT EN           1800 AUFSPALT
001140003 WERD EN                   3130 WERD
001140008 TRANSPORTIER T            5380 TRANSPORTIER
001150003 FLIES* EN                 2130 FLIES*
001160002 VEREINIG EN               1130 VEREINIG
001160011 DIEN ENDEN                1500 DIEN
001160024 VER LA*S* T               2300 VERLASS
001170017 BE STEH T                 2300 BESTEH
001230001 STEH T                    2300 STEH
001230013 KANN                      4300 KO*NN
001230021 ARBEIT EN                 1130 ARBEIT
001230023 MUS*                      4300 MU*SS
001230036 ER ZEUG EN                1130 ERZEUG
```

```
001240003 LIEFER N                    1130 LIEFER
001240012 UM GE WANDEL T              1800 UMWANDEL
001240013 WERD EN                     3130 WERD
001240014 MUS*                        4300 MU*SS
001240022 AB GE GEB EN                2800 ABGEB
001240023 WIRD                        3300 WERD
001270001 WASSER                      1300 WASSER
001320014 UM WANDEL N                 1130 UMWANDEL
001320016 NUTZ EN                     1130 NUTZ
001320020 BESSER                      1300 BESSER
001320035 AN GE GEB ENEN              2700 ANGEB
001320038 ARBEIT EN                   1130 ARBEIT
001330002 UNTER LIEG T                2300 UNTERLIEG
001340010 VERLANG T                   1380 VERLANG
001340011 WIRD                        3300 WERD
001340013 BRAUCH T                    1300 BRAUCH
001340023 ER ZEUG EN                  1130 ERZEUG
001340032 U*BER STEIG T               2300 U*BERSTEIG
001350002 ER WEIS EN                  2130 ERWEIS
001360003 ERMO*GLICH T                1380 ERMO*GLICH
001360013 ARBEIT EN                   1130 ARBEIT
001360023 DECK EN                     1130 DECK
001430001 VER BESSER TE               1470 VERBESSER
001450019 SIND                        3300 SEIN
001450032 GEGEN U*BER GE STELL T      1800 GEGENU*BERSTELL
001460002 AUS GE ZOG ENEN             2700 AUSZIEH
001460004 GEB EN                      2130 GEB
001460008 GE STRICHEL TEN             1700 STRICHEL
001460010 GE SCHA*TZ TE               1700 SCHA*TZ
001470004 WURD E                      3400 WERD
001470013 GE BAU T                    1800 BAU
001470015 KOST ETE                    1400 KOST
001480002 SOLL TEN                    4400 SOLL
001480011 LIEG EN                     2130 LIEG
001480027 PRODUZIER T                 5380 PRODUZIER
001480028 WERD EN                     3130 WERD
001480029 KO*NN EN                    4138 KO*NN
001490003 SETZ T                      1300 SETZ
001490015 GE WORD EN                  3800 WERD
001490016 IST                         3300 SEIN
001490023 AUF NEHM EN                 2130 AUFNEHM
001490024 KANN                        4300 KO*NN
```

Le programme .VERBAL2, dont nous venons de survoler les grands axes, donne lieu à deux sorties distinctes, .TRANSIT3 avec les résultats intermédiaires et .TRANSIT6 qui correspond au fichier d'entrée de l'analyse verbale .TRANSIT2 (mots commençant par une minuscule et non codés par **PROLOG** (mots outils simples ou disjoints) débarrassé des formes verbales.
En résumé :

PROLOG	agit sur	.TEXALL1.SORTIEØ.BASE	Texte à analyser
	en utilisant	.FIXALL(EXPRALL) .FIXALL(OUTALL)	Mots outils disjoints Mots outils simples
	résultat :	.TRANSIT1	Texte complet Codage des mots outils Codage de la partie numérale
		.TRANSIT2	Mots débutant par minuscule et non codés et premiers mots de phrase
		.TRANSIT5	Mots débutant par majuscule, sans les premiers mots de phrase
VERBAL	agit sur	.TRANSIT2	
	en utilisant	.MORPHAL(ENDUNG) .MORPHAL(PREFI) .MORPHAL(VERBRG) .MORPHAL(VERBIR) .MORPHAL(DESI)	Terminaisons verbales Préverbes + Collisions Racines "régulières" Racines "fortes" Désinences
	résultat :	.TRANSIT3	Résultats intermédiaires Codage
		.TRANSIT6	Mots, en minuscule, non codés
MELANGE	utilise	.TRANSIT1 .TRANSIT3	
	résultat :	.TRANSIT7	Texte complet avec codage - Mots outils - Partie numérale - Verbe

4.3.2.3 La majuscule en début de phrase (DESAMB)

- Ne sont pas encore codés, à ce stade du traitement, les mots en tête de phrase et les adjectifs/adverbes.

Le but du présent module sera de désambiguïser la majuscule de tête en distinguant les noms et les adjectifs/adverbes, puis de nettoyer ces derniers afin de dégager un fichier de travail pour le module **ADV**.

- Nous disposons à cet effet du texte complet avec les mots-outils, la partie numérale et le verbe codés :

.TRANSIT7 :

```
*0015
0017
0017
0000
0000
0001 008
0002 005 014
0002 007 016
0000
00015004240001       $SAURE
00015004250002  $00  $ELEKTROLYTE
00015004260003 5130  TRANSPORTIEREN
00015004270004  $00  $WASSERSTOFF-$IONEN
00015004280005       (
00015004290006  $02  $H+
00015004300007       )
00015004310008       ,
00015004320009  P05  IN
00015004330010       ALKALISCHEN
00015004340011  $00  $ELEKTROLYTEN
00015004350012 1130  WANDERN
00015004360013  $00  $HYDROXID-$IONEN
00015004370014       (
00015004380015  $00  $O$H(--)
00015004390016       )
00015004400017       .
```

- de .TRANSIT5 issu de **PROLOG**, avec tous les mots à majuscule sauf les mots en tête de phrase, autrement dit, tous les mots simples pour lesquels il n'y a aucun doute sur la nature de la majuscule.

.TRANSIT5 :

```
...TRANSIT5
0000200000990003 $JAHRZEHNT
0000200014000008 $ELEKTRIZITA*TSWERK
0000200021000015 $WIRKUNGSGRAD
0000200026000020 $SCHMUTZ
0000200039000024 $LA*RM
0000300041000004 $KANDIDAT
0000300044000007 $BRENNSTOFFZELLE
0000400048000002 $BRENNSTOFFZELLE
0000400052000006 $ENERGIE
0000400054000008 $BRENNSTOFFS
0000400060000014 $UMWEG
0000400063000017 $WA*RME
0000400066000020 $ELEKTRIZITA*T
0000500072000004 $SIR
0000500073000005 $WILLIAM
0000500074000006 $GROVE
0000500078000010 $JURIST
0000500081000013 $GERA*T
0000500092000024 $RECHT
0000600098000004 $GEMINI-
0000600100000006 $APOLLO-$RAUMSCHIFFE
0000600102000008 $ENERGIE
0000600111000017 $ANWENDUNG
0000700116000004 $BRENNSTOFFZELLEN
0000700122000010 $VERSIONEN
0000700131000019 $STADIUM
0000700141000029 $BEITRAG
0000700144000032 $ELEKTRIZITA*TSVERSORGUNG
0000800150000002 $BRENNSTOFFZELLE
0000800152000004 $BILD
0000800158000010 $ELEKTRODEN
```

- de .TRANSIT6 issu de **VERBAL**, avec tous les mots à minuscule qui ne sont pas codés et qui ne sont donc ni mot-outil ni verbe.

.TRANSIT6 :

```
00002000000002 NA*CHSTEN
00002000200014 HOHEN
00002000330027 RASCH
00004000510005 CHEMISCHE
00004000550009 DIREKT
00005000770009 ENGLISCHER
00006001000014 EXOTISCHE
00006001100016 TEURE
00007001210009 GRO*S*EREN
00007001400028 NENNENSWERTEN
00007001430031 O*FFENTLICHEN
00008001610013 POSITIVEN
00008001680020 NEGATIVEN
00009001870006 POSITIV
00009001890008 NEGATIV
00009002030022 NEGATIV
00009002120031 METALLISCHEN
00009002140033 VERANTWORTLICH
00011002620019 E
00012002690005 PORO*S
00013003430024 NORMALEN
00013003460027 VOLLSTA*NDIG
00013003720053 ELEKTRISCHEN
00014003970008 CHEMISCHEN
00015004330010 ALKALISCHEN
00016004650025 FESTES
00017004790011 GLEICHFALLS
00017004840016 CHEMISCHEN
00018005030009 THEORETISCH
00018005080014 NORMALEN
00018005110017 NORMALER
00020005590022 CHEMISCHEN
00021005740002 EINFACHE
00024006670005 EINFACHE
00024006710009 TECHNISCHE
00024006800018 KLEIN
```

Un ensemble de 7 tests permet de résoudre tous les cas que nous avons rencontrés jusqu'ici. Ils sont de 2 types.

Les uns utilisent la mémoire du texte et sont d'autant plus performants que le texte est long, les autres sont liés à l'improbabilité de certaines distributions.

.TRANSIT8 reprend le texte complet et y incorpore les résultats.

.TRANSIT9 ne contient que les résultats.

Test 1 : Comparaison du premier mot de la phrase avec les éléments de .TRANSIT5 Maintien de la majuscule en cas d'identité. (La comparaison s'effectue à la dernière lettre près).

.TRANSIT8 :

```
*0006
0018
0018
0000
0000
0000
0000
0000
0000
000060001.N001  $00 $BRENNSTOFFZELLEN
.V0020002000000 1470 VERSORGTEN
000060000300N003  IVK DIE
00006000400000  $00 $GEMINI-
00006000500000  M0+ UND
000060006*N003  $00 $APOLLO-$RAUMSCHIFFE
0000600070P007  P00.MIT
000060008*P007  $00.$ENERGIE
00006000900000  M01 UND
.V0100010000000 2400 FANDEN
0000600110000   B00 DAMIT
0000600120N012  JS0 EINE
0000600130000*  L00 EBENSO
0000600140000*  Z00 EXOTISCH0E
0000600150000*  L00 WIE
0000600160000*  Z00 TEUER0E
000060017*N012  $00 $ANWENDUNG
00006001800000      .
```

Test 2 : Comparaison à la dernière lettre près du premier mot de la phrase avec les éléments de .TRANSIT6

Retrait de la majuscule en cas d'identité.

```
*0015
0017
0017
0000
0000
0001 008
0002 005 014
0002 007 016
0000
0001500010N001  Z00 SAUER@E
0001500002*N001  $00 $ELEKTROLYTE
.V0030000000000 5130 TRANSPORTIEREN
0001500004.N004  $00 $WASSERSTOFF-$IONEN
0001500005+0000      (
0001500006.N006  $00 $H+
0001500007000000     )
0001500008000000  ,01 ,
0001500009P000  P00.IN
0001500010000000  Z00.ALKALISCH@EN
0001500011*P000  $00.$ELEKTROLYTEN
.V0129012000000 1130 WANDERN
0001500013.N013  $00 $HYDROXID-$IONEN
0001500014+0000      (
0001500015.N015  $00 $O$H(--)
0001500016000000     )
0001500017000000     .

*0070
0030
0030
0000
0000
0001 012
0001 018
0001 021
0000
0007000010N001  Z00 KLEIN@E
0007000002*N001  $00 $STAPEL
0007000003@P003  P00.VON
0007000004*P003  $00.$PHOSPHORSA*URE-$ZELLEN
0V0050000500000 3130 HABEN
0007000006000000  A00 HEUTE
0007000007000005  A00 SCHON
0007000008N008  Z00 VIEL@E
0007000009000000  C01 TAUSEND
0007000010*N008  $00 $BETRIEBSSTUNDEN
*V0050011100000 1300 ERREICHT
0007000012000000  ,01+,
0007000013000000  M01 ABER
0007000014N014  I0K DIE
0007000015@P015  P00.U*BER
0007000016000000  C01.VIERZIGTAUSEND
0007000017000000  $00.$STUNDEN
0007000018+0000     .(
0007000019*00000  C01.VIEREINHALB
0007000020*0000  $00.$JAHRE
0007000021*P015     .)
0007000022000000 2Z00 GEHEND@E
0007000023000000  $00 $DAUERPRU*FUNG
0007000024000000  JS0 EINES
0007000025000000  Z00 GROS*@EN
0007000026*N014  $00 $STAPELS
0V0270027000000 2300 STEHT
0007000028000000  AM* NOCH
*V0270029000000  000 AUS
0007000030000000     .
```

Test 3 : Lorsqu'une phrase se réduit à un mot, il s'agit d'un mot majuscule

```
0000100000000
0000100000000      ;;
000010001.N001  $00 $BRENNSTOFFZELLENKRAFTWERKE
0000100000000      ;;
0000100020000      .
```

Test 4 : Si le mot est un mot composé par tiret, il prend le profil du dernier segment

```
*0075
0018
0018
0000
0000
0000
0000
0000
0000
000750001.N001  $00 $CARBONAT-$ZELLEN
.V000000200000 1130 ERZEUGEN
000750000390003  JS0 EINE
000750004*N003  $00 $SPANNUNG
000750000500005  P00.VON
000750006000000  C00.00,785
000750007*P005  $00.$VOLT
000750008000000  M01 UND
.V000000000000 3130 HABEN
000750010.N010  $00 $LEISTUNGSDICHTEN
000750011000011  P00.ZWISCHEN
000750012000000  C00.01.1
000750013000000  M0+.UND
000750014000000  C00.01.3
000750015*P011  $00.$KILOWATT
000750016000016  P00.PRO
000750017*P016  $00.$QUADRATMETER
000750018000000      .
```

Test 5 : Si le mot est suivi d'une conjonction de coordination et d'un mot à majuscule, il conserve la majuscule.

```
*0192
0053
0053
0030
0000
0003 012 020 046
0002 010 029
0002 015 036
0000
0010200001.N001  $00 $NOTSTROMAGGREGATE
0010200002000000  M0+ UND
0010200003.N003  $00 $GERA*TE
0010200040P004  P00.FU*R
0010200050000  I00.DIE
0010200060000  Z00.ELEKTRISCH0E
0010200070000  $00.$VERSORGUNG
0010200080000  AZ1.KLEIN0ERN
0010200090000  $00.$EINHEITEN
0010200010+0000     .(
0010200011N0000  $00.$GABELSTAPLER
0010200012N0000     .,
0010200013N0000 5200.AUTOMATISIERTE
0010200014N0000  $00.$HES*STATIONEN
0010200015*P004     .)
0010200160P016  P00.BIS
0010200017*P016  A00.HINAB
0010200180P018  P00.ZU
0010200019*P018  $00.$SPANNUNGSQUELLEN
0010200200000  ,01 ,
0010200210R021  K00 DIE
0010200220P022  P00.IN
0010200230000  I00.DEN
0010200240000  Z00.MENSCHLICH0EN
0010200250*P022  $00.$KO*RPER
0V0260026OR021 5380 IMPLANTIERT
0V0260027OR021 3130 WERDEN
*V0260028OR021 4130 KO*NNEN
0010200290+0000      (
0010200300000  A00 BEISPIELSWEISE
0010200310P031  P00.FU*R
0010200320000  I00.DEN
0010200330000  $00.$ANTRIEB
0010200340000  J00.EINES
0010200350*P031  $00.$HERZSCHRITTMACHERS
0010200360000      )
0010200370000  M01 UND
0010200380P038  P00.MIT
0010200390*P038  $00.$TRAUBENZUCKER
0010200400P040  P00.AUS
0010200410000  I00.DEM
0010200420000  $00.$BLUT
0010200430A043  *01.ALS
0010200440*P040  $00.$BRENNSTOFF
.V0450045*R021 1130 ARBEITEN
0010200460000  ,01 ,
.V0470047OR000 2130 STEHEN
0010200480000  A00 HIER
0010200490P049  P00.IM
0010200500000  $00.$VORDERGRUND
0010200510000  I00.DES
0010200520*P049  $00.$INTERESSES
0010200530000      .
```

Test 6 : Si le mot précède un mot à majuscule suivi d'un verbe, il perd la majuscule (Ce n'est pas sûr, mais assez probable !).

```
*0003
0014
0014
0000
0000
0000
0000
0000
0000
0000838001@N001  Z00 GU*NSTIG0E
0000000002*N001  $00 $ECHA*TZUNGEN
.V0003000300003 2130 KOMMEN
0000300034@P004  P00.FU*R
0000000500002    I00.DIE
0000000006*P004  $00.$CARBONAT-$ZELLE
0000000070P007   P00.AUF
0000000000000    Z00.A*HNLICH0E
0000000009*P007  $00.$PRODUKTIONSKOSTEN
0000000100000    DL0 WIE
0000000110P011   P00.FU*R
0000000120000    I00.DIE
0000000013*P011  $00.$PHOSPHORSA*URE-$ZELLE
0000000140000        .
```

Test 7 : Dans tous les autres cas que ceux que nous venons de citer, le mot conservera sa majuscule.

4.3.2.4 Les adjectifs et les adverbes

Dans le prolongement du module **VERBAL** et après la désambiguïsation de la majuscule en début de phrase, le codage des adjectifs et des adverbes marque la fin du niveau Ø.
Le module **ADV** doit afficher un code qui facilite le repérage des groupes nominaux tout en respectant certaines contraintes. Il est en effet hors de question d'utiliser un dictionnaire, encore moins de parcourir la phrase pour sonder le contexte.
Si l'analyse effectuée dans ces conditions ne peut être que superficielle, elle doit cependant fournir tous les éléments qui permettront de l'affiner en cas de besoin.
Nous partirons du principe que le champ des investigations recouvre l'adjectif qualificatif épithète, l'adjectif qualificatif attribut et l'adverbe, les deux derniers ayant un statut flexionnel identique.
L'examen des formes testées, par la droite et à l'aide de petits tableaux, grâce à un programme de 370 lignes, s'applique à **.TRANSIT8**, texte complet avec majuscules de début de phrase désambiguïsées et codage de tous les enregistrements autres que les adjectifs qualificatifs et les adverbes absents de **.FIXALL(OUTALL)** et **.FIXALL(EXPRALL)**.

.TRANSIT8

```
52015 660001  P00 MIT
52015 670002  $00 $O*L
52015 680003  N0+ ODER
52015 690004  $00 $KOHLE
52015 700005  *01 ALS
52015 710006      PRIMA*REN
52015 720007  $00 $BRENNSTOFFEN
52015 730008 3300 SIND
52015 740009  IVK DAS
52015 750010  F00 #VOR#ALLEM
52015 760011  $00 $SCHWEFELDIOXID
52015 770012  N0+ UND
52015 780013  $00 $STICKSTOFFOXID
52015 790014      ,
52015 800015  AN0 DOCH
52015 810016 2300 LIEGT
52015 820017  IVK DIE
52015 830018  $00 $SCHWEFELDIOXID-$EMISSION
52015 840019  A00 BESONDERS
52015 850020      NIEDRIG
52015 860021      ,
52015 870022  N00 WEIL
52015 880023  IVK DIE
52015 890024  $00 $BRENNSTOFFZELLE
52015 900025  P00 GEGEN
52015 910026  $00 $SCHWEFELVERBINDUNGEN
52015 920027      EMPFINDLICH
52015 930028 3300 IST
52015 940029      ,
52015 950030  N00 @SO@DAS*
52015 960031  V00 DIESE
52015 970032  F00 IN
52015 980033  IVK DER
52015 990034  $00 $BRENNSTOFF-$AUFBEREITUNGSANLAGE
52016 000035 1300 ENTFERNT
52016 010036 3130 WERDEN
52016 020037 4130 MU*SSEN
52016 030038      .
```

Dans le tableau qui suit, nous résumerons les problèmes à résoudre. Ces derniers sont d'ordre morphologique, étant donné le niveau d'analyse (niveau Ø).

L'adjectif qualificatif attribut et l'adverbe qualificatif portant une désinence identique et de ce fait un code ambigu (AZØ), nous attribuerons le code (AØØ) aux adverbes repérés grâce à leur suffixation (*falls, lings...*). L'analyse s'applique aux participes (présent et passé) déclinés.

POSITIF	Adj. épithète ZØØ	Désinences : Particularités :	-e, -em, -en, -es, -er syncope du **e** pour certains radicaux *hoh* -e de *lange* (adv)
	Adj. attribut Adverbe qual. AZØ	Désinence :	Ø
COMPARATIF SUPERIORITE	Adj. épithète ZØ1	Désinences : Particularités :	(")ere, (")erem, (")eren, (")eres, (")erer GUT, WOHL, HOCH VIEL, GERN, NAH, WENIG
	Adj. attribut Adverbe qual. AZ1	Désinence :	(")er
SUPERLATIF	Adj. épithète ZØ2	Désinences : Particularités :	-(e)ste, -(e)stem, -(e)sten, -(e)ster, -(e)stes GROß, GUT, WOHL HOCH, VIEL, NAH, GERN, WENIG
	Adj. attribut Adverbe qual. AØ2	Désinences : Particularités :	am ... (")sten am ... (e)sten - irréguliers : hoch - -ßt, -st : möglichst - formes figées : *mindestens, meistens*

Le système des désinences n'enregistre qu'une collision :

-ER code AZ1
- adj. épithète (déclinaison forte)
- adj. attribut et adv. qualificatif au comparatif de sup.

Le code est à 3 caractères. Dans le cas d'un participe passé décliné (X7ØØ) ou d'un participe présent décliné (X5ØØ), il se superpose aux trois derniers caractéres du code verbal.

AØØ adverbe
AØ2 adverbe qual. et adj. attribut au superlatif
ZØØ adj. qualificatif épithète
ZØ1 adj. qualificatif épithète au comparatif sup.
ZØ2 adj. qualificatif épithète au superlatif
AZØ adj. qualificatif attribut/adverbe qualificatif
AZ1 adj. qualificatif épithète/adverbe qualificatif et adj. qualificatif attribut au comparatif de sup.

La comparaison de la partie finale du mot testé avec les données du fichier **.FIXALL(DEGRE)** ne peut pas se dérouler sans quelques précautions. Ces dernières répondent aux particularités énoncées dans le tableau de la page précédente et s'appuient sur trois tableaux:

.FIXALL(ADJER) pour les adjectifs en -ER,
.FIXALL(ADJST) pour les adjectifs en -(E)ST
.FIXALL(COMPSUP) pour les irrégularités

.FIXALL(DEGRE) :

```
00010 .FIXALL(DEGRE)
00020 30033
00030 0037
00040 0021
00050 0006
00060 A02ESTENS
00070 Z02ESTEN
00080 Z02ESTEN
00090 Z02ESTER
00100 Z02ESTES
00110 Z02ESTE
00120 A02EST

00140 Z02STEN
00150 Z02STEN
00160 Z02STER
00170 Z02STES
00180 Z02STE
00190 A02ST
00200 A02S*TENS
00210 Z02S*TEN
00220 Z02S*TEN
00230 Z02S*TER
00240 Z02S*TES
00250 Z02S*TE
00260 A02S*T
00270 Z01EREN
00280 Z01EREN
00290 Z01ERER
00300 Z01ERES
00310 Z01ERE
00320 AZ1ER
```

.FIXALLL(ADJER) :

```
00010 .FIXALL(ADJER)
00020 38083
00025 0015
00030 AND
00040 NIED
00050 OB
00060 UNT
00070 LOCK
00080 LE
00090 TAPF
00100 TEU
00110 SAU
00120 HAG
00130 MAG
00140 STI
00150 INTEG
00160 SICH
00170 WACK
```

.FIXALL(ADJST) :

```
00010 .FIXALL(ADJST)
00020 SELBST
00030 MODEST
00040 FEST
00050 MEIST
00060 LIST
00070 MIST
00080 NIST
00090 OIST
00100 PIST
00110 RIST
00120 TIST
00130 VIST
```

.FIXALL(COMPSUP) :

```
00010 .FIXALL(COMPSUP)
00020 BESS
00030 GRO*S*
00040 HO*H
```

La présence des suffixes adverbiaux permet d'éviter l'insertion dans le dictionnaire des mots outils d'un grand nombre d'unités qu'il est facile de repérer.

.FIXALL(ADVER) :

```
00010 .FIXALL(ADVER)
00020 35083
00030 0511
00040 FALLS
00050 LINGS
00060 MAS*EN
00070 SEITS
00080 TEILS
00090 WA*RTS
00100 WEGS
00110 WEISE
00120 MALS
00130 MAL
00140 EMS
```

Obtenus en moins d'une seconde sur les 149 phrases du texte, les résultats sortent sur deux fichiers, **.TRANSI10** qui ne comporte que les résultats et **.TRANSI11** qui les a incorporés dans le texte. C'est ce fichier qui servira de départ à l'analyse syntaxique (niveau 2).

```
ØØØ32ØØ3Ø6ØØØ2  ZØ2 NAH@ST#EN
ØØØ32ØØ3Ø22Ø14  ZØØ HOH@EN
ØØØ32ØØ3Ø22ØØ27  AZØ RASCH
ØØØ33ØØ3Ø7ØØØ2  AZØ VIEL
ØØØ33ØØ4Ø4ØØØ3 2AZ1 VERSPRECHEND@ER#
ØØØ4ØØØ5Ø1ØØØ5  ZØØ CHEMISCH@E
ØØØ34ØØØ55ØØØ9  AZØ DIREKT
ØØØ35ØØØ77ØØØ9  AZ1 ENGLISCH@ER#
ØØØ35ØØØ86ØØ16  AØØ LANG@E
ØØØ36ØØ1ØØØØ14  ZØØ EXOTISCH@E
```

```
ØØØ42Ø1231ØØ24 2ZØØ ENTHALTEN@E
ØØØ42Ø1237ØØ3Ø 1AZØ UNVERA*NDERT
ØØØ43Ø1252ØØ18  ZØØ O*FFENTLICH@E
ØØØ43Ø1264ØØ2Ø 2ZØØ ANGESCHLOSSEN@EN
ØØØ44Ø1271ØØØ2  ZØØ ERST@ER
ØØØ44Ø129ØØØ21  ZØ1 KLEIN@ER#EM
ØØØ44Ø1299ØØ3Ø  ZØØ FEST@E
```

```
ØØØ5ØØ15ØØØØØ5  AZØ WIRTSCHAFTLICH
ØØØ5ØØ1511ØØØ2  ZØØ NORMAL@ES
ØØØ5ØØ152ØØØ17  ZØØ DURCHSCHNITTLICH@EN
ØØØ5ØØ1527ØØ24  AZ1 VOLL@ER#
ØØØ5ØØ154ØØØ37  AZØ LASTABHA*NGIG
ØØØ51Ø1563ØØ14  ZØØ UMWELTBELASTEND@E
ØØØ52Ø1571ØØØ6  ZØØ PRIMA*R@EN
ØØØ52Ø1585ØØ2Ø  AZØ NIEDRIG
ØØØ52Ø1592ØØ27  AZØ EMPFINDLICH
ØØØ54Ø1625ØØØ4  AZØ MO*GLICH
ØØØ54Ø1628ØØ27  ZØØ SOLCH@E
ØØØ54Ø1631ØØ13  AZ1 UNMITTELBAR@ER#
ØØØ54Ø1642ØØ21  AZ1 NEU@ER#
```

.TRANSIT11 :

```
00002000060000       $
00002000070001  G00 IM
00002000080002  Z02 NAH@ST@EN
00002000090003  $00 $JAHRZEHNT
00002000100004 3300 WIRD
00002000110005  *05 MAN
00002000120006  P00 VON
00002000130007  JS0 EINEM
00002000140008  $00 $ELEKTRIZITA*TSWERK
00002000150009 1130 FORDERN
00002000160010       ,
00002000170011  N00 DAS*
00002000180012  Y00 ES
00002000190013  JS0 EINEN
00002000200014  Z00 HOH@EN
00002000210015  $00 $WIRKUNGSGRAD
00002000220016 3300 HAT
00002000230017       ,
00002000240018  A02 MO*GLICHST
00002000250019  A00 WENIG
00002000260020  $00 $SCHMUTZ
00002000270021 5300 EMITTIERT
00002000280022       ,
00002000290023  S00 KEINEN
00002000300024  $00 $LA*RM
00002000310025 1300 VERURSACHT
00002000320026  M0+ UND
00002000330027  AZ0 RASCH
00002000340028  *04 ZU
00002000350029 5130 INSTALLIEREN
00002000360030 3300 IST
00002000370031       .

00015004240001  Z00 SAUER@E
00015004250002  $00 $ELEKTROLYTE
00015004260003 5130 TRANSPORTIEREN
00015004270004  $00 $WASSERSTOFF-$IONEN
00015004280005       (
00015004290006  $00 $H+
00015004300007       )
00015004310008       ,
00015004320009  P00 IN
00015004330010  Z00 ALKALISCH@EN
00015004340011  $00 $ELEKTROLYTEN
00015004350012 1130 WANDERN
00015004360013  $00 $HYDROXID-$IONEN
00015004370014       (
00015004380015  $00 $O$H(--)
00015004390016       )
00015004400017       .
```

```
00100027580001  JSÖ EIN
00100027590002  APÖ AUS
00100027600003  Z00 SOLCH@EN
00100027610004  $00 $ZELLEN
00100027620005 2Z00 BESTEHEND@ES
00100027630006  $00 $KRAFTWERK
00100027640007      ,
00100027650008 4300 SOLL
00100027660009  $00 $KOHLE
00100027670010  *01 ALS
00100027680011  Z00 PRIMA*R@EN
00100027690012  $00 $BRENNSTOFF
00100027700013 1130 VERWENDEN
00100027710014 4138 KO*NNEN
00100027720015      ,
00100027730016  U00 SEINE
00100027740017  $00 $LEISTUNG
00100027750018 3300 WIRD
00100027760019  V00 EINIGE
00100027770020  C01 HUNDERT
00100027780021  $00 $MEGAWATT
00100027790022 2138 BETRAGEN
00100027800023      ,
00100027810024  M0+ UND
00100027820025  *05 MAN
00100027830026 1300 RECHNET
00100027840027  P00 MIT
00100027850028  JS0 EINER
00100027860029  $00 $ENTWICKLUNGSZEIT
00100027870030  P00 VON
00100027880031  A00 ETWA
00100027890032  C01 ZEHN
00100027900033  $00 $JAHREN
00100027910034      .

00018004950001  JS0 EINE
00018004960002  P00 MIT
00018004970003  $00 $WASSERSTOFF
00018004980004  M0+ UND
00018004990005  $00 $SAUERSTOFF
00018005000006 2Z00 BETRIEBEN@E
00018005010007  $00 $ZELLE
00018005020008 3300 IST
00018005030009  AZ0 THEORETISCH
00018005040010  P00 IN
00018005050011  IVK DER
00018005060012  $00 $LAGE
00018005070013  PA0 BEI
00018005080014  Z00 NORMAL@EM
00018005090015  $00 $DRUCK
00018005100016  M0+ UND
00018005110017  AZ1 NORMAL@ER#
00018005120018  $00 $TEMPERATUR
00018005130019  JS0 EINE
00018005140020  $00 $SPANNUNG
00018005150021  P00 VON
00018005160022  AZ0 1,23
00018005170023  $00 $VOLT
00018005180024  *04 ZU
00018005190025 1130 LIEFERN
00018005200026      .
```

```
00007001130001  A00 HEUTE
00007001140002 2300 GIBT
00007001150003  Y00 ES
00007001160004  $00 $BRENNSTOFFZELLEN
00007001170005  P00 IN
00007001180006 1470 VERBESSERTEN
00007001190007  N0+ UND
00007001200008  Z00 TAUSEND-MAL
00007001210009  Z01 GRO*S*@ER#EN
00007001220010  $00 $VERSIONEN
00007001230011      ,
00007001240012  N0+ UND
00007001250013  Y00 ES
00007001260014 2300 SCHEINT
00007001270015      ,
00007001280016  *01 ALS
00007001290017 DA00 SEI
00007001300018  IVK DAS
00007001310019  $00 $STADIUM
00007001320020 1380 ERREICHT
00007001330021      ,
00007001340022  P00 IN
00007001350023  IVK DEM
00007001360024  *05 MAN
00007001370025  P00 VON
00007001380026  Y00 IHNEN
00007001390027  JS0 EINEN
00007001400028  Z00 NENNENSWERT@EN
00007001410029  $00 $BEITRAG
00007001420030  G00 ZUR
00007001430031  Z00 O*FFENTLICH@EN
00007001440032  $00 $ELEKTRIZITA*TSVERSORGUNG
00007001450033 1130 ERWARTEN
00007001460034 4300 KANN
00007001470035      .
```