



HAL
open science

Détection des lésions dentaires sur radiographie rétro-alvéolaire par apprentissage profond : une étude pilote

Simon Germain

► To cite this version:

Simon Germain. Détection des lésions dentaires sur radiographie rétro-alvéolaire par apprentissage profond : une étude pilote. Sciences du Vivant [q-bio]. 2023. hal-04517102

HAL Id: hal-04517102

<https://hal.univ-lorraine.fr/hal-04517102v1>

Submitted on 22 Mar 2024

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.



**UNIVERSITÉ
DE LORRAINE**

**BIBLIOTHÈQUES
UNIVERSITAIRES**

AVERTISSEMENT

Ce document est le fruit d'un long travail approuvé par le jury de soutenance et mis à disposition de l'ensemble de la communauté universitaire élargie.

Il est soumis à la propriété intellectuelle de l'auteur. Ceci implique une obligation de citation et de référencement lors de l'utilisation de ce document.

D'autre part, toute contrefaçon, plagiat, reproduction illicite encourt une poursuite pénale.

Contact bibliothèque : ddoc-thesesexercice-contact@univ-lorraine.fr
(Cette adresse ne permet pas de contacter les auteurs)

LIENS

Code de la Propriété Intellectuelle. articles L 122. 4

Code de la Propriété Intellectuelle. articles L 335.2- L 335.10

http://www.cfcopies.com/V2/leg/leg_droi.php

<http://www.culture.gouv.fr/culture/infos-pratiques/droits/protection.htm>

**ACADÉMIE DE NANCY-METZ
UNIVERSITÉ DE LORRAINE
FACULTÉ D'ODONTOLOGIE DE LORRAINE**

Année 2023

N°

THÈSE

POUR LE DIPLÔME D'ÉTAT DE DOCTEUR EN CHIRURGIE DENTAIRE

Présentée et soutenue publiquement le :

22 septembre 2023

Par

Simon GERMAIN

Né le 19 décembre 1992 à Essey-lès-Nancy (54)

**Détection des lésions dentaires sur radiographie rétro-alvéolaire
par apprentissage profond : une étude pilote.**

Composition du Jury :

Président :

Pr E. MORTIER

Membre :

Dr M. HOMBOURGER

Co-directeurs :

Dr D. JOSEPH

Dr K. YASUKAWA

*Par délibération en date du 11 décembre 1972,
la Faculté de Chirurgie Dentaire a arrêté que
les opinions émises dans les dissertations
qui lui seront présentées
doivent être considérées comme propres à
leurs auteurs et qu'elle n'entend leur donner
aucune approbation ni improbation*

Présidente : Docteur Héléne BOULANGER

Doyen : Docteur Kazutoyo YASUKAWA

Vice-Doyens : Dr Charlène KICHENBRAND – Dr Rémy BALTHAZARD – Dr Marin VINCENT

Membres Honoraires : Dr L. BABEL – Pr. S. DURIVAUX – Pr A. FONTAINE – Pr G. JACQUART – Pr D. ROZENCWEIG - Pr ARTIS

Doyens Honoraires : Pr J. VADOT, Pr J.P. LOUIS

| | | | |
|---|--|-------------------------------------|--|
| Département odontologie pédiatrique Sous-section 56-01 | Mme | JAGER Stéphanie | Maître de conférences * |
| | M. | PREVOST Jacques | Maître de conférences |
| | Mme | HERNANDEZ Magali | Maître de conférences * |
| | M. | HAINOT Raphaël | Chef de clinique des universités – Assistant des hôpitaux |
| | Mme | HILT Léa | Chef de clinique des universités – Assistant des hôpitaux |
| | Mme | HOMBOURGER Morgane | Chef de clinique des universités – Assistant des hôpitaux |
| | M. | MASSON Maximilien | Chef de clinique des universités – Assistant des hôpitaux |
| Département orthopédie dento-faciale Sous-section 56-01 | M. | VANDE VANNET Bart | Professeur des universités * |
| | Mme | DAMERDJI-BENHABIB Zaheira | Chef de clinique des universités – Assistant des hôpitaux ass. * |
| | M. | FAWAZ Paul | Chef de clinique des universités associé * |
| Département prévention, épidémiologie, économie de la santé, odontologie légale Sous-section 56-02 | Mme | CLÉMENT Céline | Maître de conférences * |
| | M. | BAUDET Alexandre | Maître de conférences * |
| | Mme | CAIONE Mariette | Chef de clinique des universités – Assistant des hôpitaux |
| | M. | VEYNACHTER Thomas | Chef de clinique des universités – Assistant des hôpitaux* |
| Département parodontologie Sous-section 57-01 | Mme | BISSON Catherine | Professeur des universités * |
| | M. | JOSEPH David | Maître de conférences * |
| | Mme | BERBE Ludvine | Chef de clinique des universités – Assistant des hôpitaux* |
| Département chirurgie orale Sous-section 57-01 | M. | BRAVETTI Pierre | Maître de conférences * |
| | Mme | GUILLET-THIBAUT Julie | Maître de conférences |
| | Mme | KICHENBRAND Charlène | Maître de conférences * |
| | Mme | PHULPIN Bérengère | Maître de conférences * |
| | M. | CLERC Sébastien | Praticien hospitalier universitaire * |
| | Mme | BECKER Alice | Chef de clinique des universités – Assistant des hôpitaux |
| | Mme | PEREIRA Laure | Chef de clinique des universités – Assistant des hôpitaux |
| Département biologie orale Sous-section 57-01 | Mme | EGLOFF-JURAS Claire | Maître de conférences * |
| | M. | MARTRETTE Jean-Marc | Professeur des universités * |
| | M. | YASUKAWA Kazutoyo | Maître de conférences * |
| Département dentisterie restauratrice, endodontie Sous-section 58-01 | M. | MORTIER Éric | Professeur des universités * |
| | M. | ENGELS-DEUTSCH Marc | Professeur des universités * |
| | M. | AMORY Christophe | Maître de conférences |
| | M. | BALTHAZARD Rémy | Maître de conférences * |
| | M. | VINCENT Marin | Maître de conférences* |
| | M. | GIESS Renaud | Maître de conférences associé* |
| | Mme | DAL MAGRO Claire | Chef de clinique des universités – Assistant des hôpitaux |
| | Mme | DAVRIL Jeanne | Chef de clinique des universités – Assistant des hôpitaux* |
| | M. | LESIEUR François | Chef de clinique des universités – Assistant des hôpitaux |
| Département prothèses Sous-section 58-01 | M. | DE MARCH Pascal | Maître de conférences |
| | Mme | CORNE Pascale | Maître de conférences * |
| | M. | SCHOUVER Jacques | Maître de conférences |
| | Mme | VAILLANT Anne-Sophie | Maître de conférences * |
| | M. | HIRTZ Pierre | Enseignant universitaire |
| | Mme | GERBER Caroline | Chef de clinique des universités – Assistant des hôpitaux* |
| | M. | JONVEAUX Maxime | Chef de clinique des universités – Assistant des hôpitaux |
| | Mme | MOUGEL Armande | Chef de clinique des universités – Assistant des hôpitaux |
| | M. | PERRIN Tom | Chef de clinique des universités – Assistant des hôpitaux |
| | M. | SYDA Paul-Marie | Chef de clinique des universités – Assistant des hôpitaux |
| | Mme | WILK Sabine | Chef de clinique des universités – Assistant des hôpitaux |
| | Département fonction-dysfonction, imagerie, biomatériaux Sous-section 58-01 | Mme | STRAZIELLE Catherine |
| Mme | | MOBY (STUTZMANN) Vanessa | Maître de conférences * |
| M. | | SALOMON Jean-Pierre | Maître de conférences |
| M. | | RITTIE François | Chef de clinique des universités – Assistant des hôpitaux |

Souligné : responsable de département

* temps plein

Mis à jour le 17 mars 2023

REMERCIEMENTS

À NOTRE PRÉSIDENT DU JURY DE THÈSE

Monsieur le Professeur Éric MORTIER

Docteur en chirurgie dentaire

Docteur de l'université Henri Poincaré en physique-chimie de la matière et des matériaux

Habilité à diriger des recherches

Professeur des Universités - Praticien Hospitalier

Responsable du département de dentisterie restauratrice, endodontie

Chef du service d'odontologie du CHRU de Nancy

Vous nous faites l'honneur de présider le jury de notre thèse. Nous vous remercions pour les qualités pédagogiques et humaines dont vous avez fait preuve et qui nous ont permis de progresser tout au long de notre cursus. Soyez assuré de notre reconnaissance et de notre profond respect.

À NOTRE JUGE ET CO-DIRECTEUR DE THÈSE

Monsieur le Docteur David JOSEPH

Docteur en chirurgie dentaire

Docteur de l'université de Lorraine, mention science de la vie et de la santé

Maître de Conférences - Praticien Hospitalier

Nous vous remercions d'avoir accepté la co-direction de cette thèse. Nous vous sommes reconnaissant pour votre disponibilité, votre sympathie et pour le soutien que vous nous avez apporté tout au long de nos études. Veuillez trouver ici le témoignage de notre amitié et de notre profonde gratitude.

À NOTRE JUGE ET CO-DIRECTEUR DE THÈSE

Monsieur le Docteur Kazutoyo YASUKAWA

Docteur en chirurgie dentaire

Docteur de l'Université Paris Descartes mention sciences de la vie et de la santé

Spécialiste qualifié en médecine bucco-dentaire

Maître de Conférences - Praticien Hospitalier

Doyen de la faculté d'odontologie de Lorraine

Nous apprécions l'honneur que vous nous avez fait en acceptant de co-diriger cette thèse. Nous vous remercions pour votre pédagogie et pour la qualité de vos enseignements durant nos années d'études. Vous trouverez ici le témoignage de notre gratitude et de notre profond respect.

À NOTRE JUGE

Madame le Docteur Morgane HOMBOURGER

Docteur en chirurgie dentaire

Assistant hospitalo-universitaire

Nous vous remercions pour la spontanéité avec laquelle vous avez accepté de siéger dans le jury de cette thèse. Nous avons été touchés par votre bienveillance et votre bonne humeur tout au long de cette année. Nous tenions à vous remercier pour votre disponibilité et votre soutien dans la réalisation de ce travail. Nous vous souhaitons une belle réussite professionnelle.

SOMMAIRE

LISTE DES FIGURES

LISTE DES TABLEAUX

LISTE DES ABRÉVIATIONS

INTRODUCTION

PARTIE 1 : L'APPRENTISSAGE PROFOND DANS L'ANALYSE D'IMAGE PAR ORDINATEUR

1. Définitions et généralités
2. Les réseaux de neurones profonds
3. Analyse d'image par apprentissage profond
4. Historique
5. Utilisation en santé

PARTIE 2 : RADIOGRAPHIE RÉTRO-ALVÉOLAIRE ET LÉSION DENTAIRE

1. La carie dentaire
2. La radiographie rétro-alvéolaire

PARTIE 3 : EXPÉRIMENTATION

1. Matériels et méthodes
2. Logigramme
3. Récolte et trie des données
4. Segmentation des données
5. Création du modèle algorithmique
6. Résultats
7. Discussion

CONCLUSION

BIBLIOGRAPHIE

ANNEXE

TABLE DES MATIÈRES

LISTE DES FIGURES

| | |
|--|----|
| Figure 1 : Vision schématique des différents domaines d'intelligence artificielle (Muller et coll, 2022) | 14 |
| Figure 2 : Différenciation détaillée de l'intelligence artificielle, du machine learning et du deep learning (Bunod et al, 2022) | 14 |
| Figure 3 : Différence neurone biologique et neurone artificiel (Maurice 2018) | 18 |
| Figure 4 : Schéma d'un neurone informatique superposé à un schéma de neurone biologique (Rousseau et Douarre 2021) | 18 |
| Figure 5 : Architecture du réseaux des neurones artificiels du perceptron (Chatelain et Herault 2021)..... | 19 |
| Figure 6 : Exemple de réseaux de neurones profonds (Ahirwar 2017)..... | 21 |
| Figure 7 : Réseau de neurones profonds pour classification (Université Grenoble Alpes - Supports Fidle) | 22 |
| Figure 8 : Réseau de neurones profonds avec rétropropagation en fonction d'erreur (Université Grenoble Alpes - Supports Fidle) | 23 |
| Figure 9 : Architecture schématique d'un réseau de neurone profond (Boone et al. 2023) | 24 |
| Figure 10 : Schéma du parcours de la fenêtre de filtre sur l'image (Convolutional Neural Network ou réseaux de neurones convolutifs 2020) | 25 |
| Figure 11 : Processus (à droite) et exemple d'effet (à gauche) du Max Pooling (Deep Learning Part 2) | 26 |
| Figure 12 : Etapes de l'analyse d'image par apprentissage profond (Ghaffari et Savaria 2020) | 29 |
| Figure 13 : Schéma de Keyes modifié par Newbrun (Danielle et al. 2014) | 57 |
| Figure 14 : Diagramme synthétique de l'expérimentation (Source personnelle) | 62 |
| Figure 15 : Nombre d'annotations par classe | 66 |
| Figure 16 : Nombre d'images par classe | 66 |
| Figure 17 : Nombre d'annotations par image..... | 67 |
| Figure 18 : Distribution des pixels par classe | 67 |
| Figure 19 : Radiographie rétro-alvéolaire secteur 4 sur SuperAnnotate (Source personnelle)..... | 68 |

| | |
|---|----|
| Figure 20 : Radiographie rétro-alvéolaire secteur 4 sur SuperAnnotate avec segmentation des classes (Source personnelle) | 69 |
| Figure 21 : Etapes pour la création du réseau de neurones profonds | 70 |
| Figure 22 : Cross-validation à 5 folds : Chaque point appartient à 1 des 5 jeux de test (en blanc) et aux 4 autres jeux d'entraînements (en orange)..... | 73 |
| Figure 23 : Utilisation du CLAHE sur une radiographie rétro-alvéolaire | 74 |
| Figure 24 : Application d'un changement de luminosité comme Data Augmentation | 76 |
| Figure 25 : Application d'un changement de contraste comme Data Augmentation | 76 |
| Figure 26 : Application d'un flou comme Data Augmentation | 76 |
| Figure 27 : Application d'un flip comme Data Augmentation | 76 |
| Figure 28 : Application d'une rotation comme Data Augmentation | 77 |
| Figure 29 : Application d'un zoom comme Data Augmentation | 77 |
| Figure 30 : Application du cropped comme Data Augmentation..... | 77 |
| Figure 31 : Application d'un filtre gamma comme Data Augmentation | 77 |
| Figure 32 : Imprim écran des configurations testées | 78 |
| Figure 33 : Imprim écran des résultats synthétisés dans une table | 80 |
| Figure 34 : Résultat optimal de l'IoU moyen | 81 |
| Figure 35 : Equation du calcul de l'IoU | 83 |
| Figure 36 : Schéma synthétique d'un IoU faible, bon et excellent | 83 |
| Figure 37 : Résultats du réseau de neurones des différentes classes évaluées | 84 |
| Figure 38 : Exemple 1 de prédiction donnée par le RNA..... | 85 |
| Figure 39 : Exemple 2 de prédiction donnée par le RNA..... | 86 |
| Figure 40 : Exemple 3 de prédiction donnée par le RNA..... | 86 |
| Figure 41 : Exemple 4 de prédiction donnée par le RNA..... | 87 |
| Figure 42 : Exemple 5 de prédiction donnée par le RNA..... | 87 |
| Figure 43 : Exemple 1 sur radiographie vierge de toute segmentation..... | 88 |
| Figure 44 : Exemple 2 sur radiographie vierge de toute segmentation..... | 88 |
| Figure 45 : Exemple 3 sur radiographie vierge de toute segmentation..... | 88 |
| Figure 46 : Exemple 4 sur radiographie vierge de toute segmentation..... | 89 |
| Figure 47 : Exemple 5 sur radiographie vierge de toute segmentation..... | 89 |
| Figure 48 : Matrice de confusion (nombre de pixels)..... | 90 |
| Figure 49 : Matrice de confusion (pourcentage de pixels par classe prédite) | 91 |
| Figure 50 : Matrice de confusion (pourcentage de pixels par classe réelle) | 92 |

LISTE DES TABLEAUX

Tableau 1 : Avantages et inconvénients de l'apprentissage profond53

LISTE DES ABREVIATIONS

| Abréviations | Nom Anglais | Nom Français |
|---------------------|---|---|
| API | <i>Advanced Programming Interface</i> | Interface de programmation avancée |
| CBCT | <i>Cone Beam Computed Tomography</i> | Tomographie volumétrique numérisée à faisceau conique |
| CLAHE | <i>Contrast Limited Adaptive Histogram Equalization</i> | Égalisation adaptative d'histogramme à contraste limité |
| CNN | <i>Convolutional Neural Network</i> | Réseaux de neurones convolutionnels |
| CPU | <i>Central Processing Unit</i> | Unité centrale de traitement |
| DL | <i>Deep Learning</i> | Apprentissage profond |
| DMLA | <i>Age-related macular degeneration</i> | Dégénérescence maculaire liée à l'âge |
| DNN | <i>Deep Neural Network</i> | Réseaux de neurones profonds |
| FA | <i>Atrial Fibrillation</i> | Fibrillation atriale |
| GPU | <i>Graphics Processing Unit</i> | Unité de traitement graphique |
| IA | <i>Artificial Intelligence</i> | Intelligence artificielle |
| IoU | <i>Intersection over Union</i> | Intersection sur union |
| IRM | <i>MRI</i> | Imagerie par résonance magnétique |
| LPB | <i>Periodontal Bone Loss</i> | Perte d'os parodontal |
| LTU | <i>Linear Threshold Unit</i> | Unité linéaire à seuil |
| MIT | <i>Massachusetts Institute of Technology</i> | Institut de technologie du Massachusetts |
| ML | <i>Machine Learning</i> | Apprentissage automatique |
| OCT | <i>Optical Coherence Tomography</i> | Tomographie à cohérence optique |
| RA | <i>Periodontal Radiography</i> | Radiographie rétro-alvéolaire |
| RNA | <i>Artificial Neural Network</i> | Réseau de neurones artificiels |
| SVM | <i>Support Vector Machine</i> | Machine à vecteur de support |
| TLU | <i>Threshold Logic Unit</i> | Unité logique à seuil |
| VPP | <i>Positive Predictive Value</i> | Valeur predictive positive |

INTRODUCTION

L'apprentissage profond (*deep learning*) est un type d'intelligence artificielle (IA) dérivé de l'apprentissage automatique (*machine learning*) où la machine est capable d'apprendre par elle-même, contrairement à la programmation où elle se contente d'exécuter à la lettre des règles prédéterminées.

L'apprentissage profond permet de reproduire le fonctionnement du cerveau humain et de son réseau de neurones. L'algorithme « apprend » en essayant et en faisant des erreurs avant d'agir en autonomie et de réussir la tâche qui lui a été attribué.

Au cours de ce travail, après un bref rappel sur l'apprentissage profond et ses applications dans le domaine de la santé, notamment en médecine bucco-dentaire, nous évaluerons l'utilisation de l'apprentissage profond dans l'analyse de lésions dentaires à partir de radiographie rétro-alvéolaire (RA) avec la création d'un modèle algorithmique suivant un protocole strict.

Ainsi, à partir d'une collection de radiographies rétro-alvéolaires de la dent 46, nous allons attribuer manuellement, à chaque pixel des images analysées, une classe d'origine anatomique, pathologique ou histologique.

L'expérimentation consiste en la création d'un modèle algorithmique qui après s'être entraîné avec des données que nous lui avons transmises, va pouvoir nous reconnaître de lui-même différentes classes.

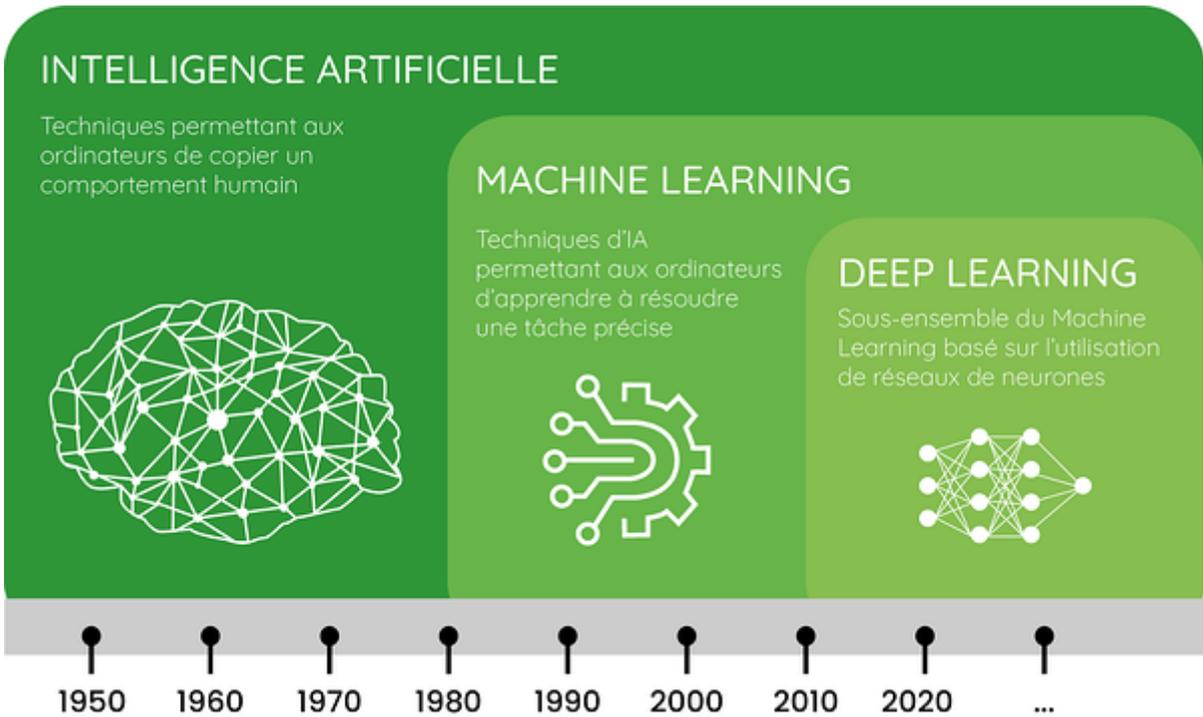


Figure 1 : Vision schématique des différents domaines d'intelligence artificielle (Muller et coll, 2022)

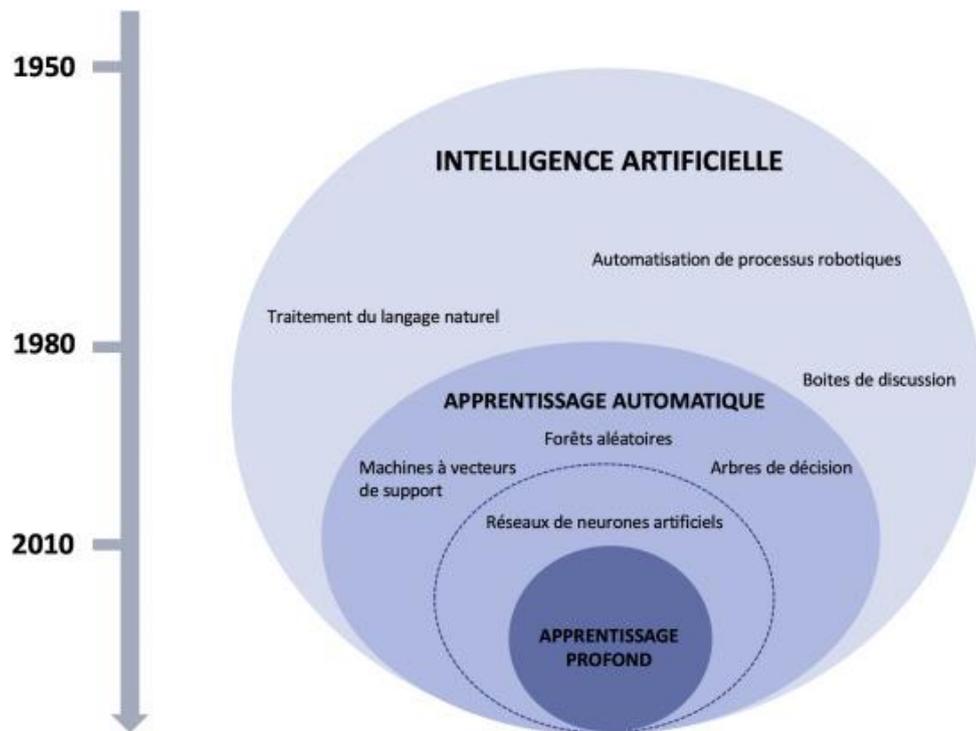


Figure 2 : Différenciation détaillée de l'intelligence artificielle, du machine learning et du deep learning (Bunod et al, 2022)

1. L'APPRENTISSAGE PROFOND DANS L'ANALYSE D'IMAGE PAR ORDINATEUR

1.1. Définitions et généralités

- Dans les années 1950, l'**intelligence artificielle** (IA) a été définie par McCarthy et al, comme une branche de l'informatique dans laquelle des approches basées sur des machines étaient utilisées pour réaliser des prédictions dans le but d'imiter ce que l'intelligence humaine pourrait faire dans une même situation
(Jiang et al. 2020)

L'IA implique l'utilisation d'un ordinateur pour modéliser un comportement intelligent avec une intervention humaine minimale.

- **L'apprentissage automatique** ou *machine learning* fait partie intégrante de l'IA en se définissant comme la science et l'art de programmer les ordinateurs de sorte qu'ils puissent apprendre à partir de données et s'améliorer avec l'expérience.
- En 1959, Arthur Samuel définit l'apprentissage automatique comme la discipline donnant aux ordinateurs la capacité d'apprendre sans qu'ils soient explicitement programmés. (Géron 2019)

Un système d'apprentissage automatique passe en général par deux phases.

- Premièrement la phase d'apprentissage ou l'ordinateur (son algorithme) est entraîné sur un jeu de données d'entraînement.
- Puis, la phase d'inférence, où le système applique ce qu'il a appris des données précédentes sur de nouvelles données.

L'apprentissage automatique peut être divisé en apprentissage supervisé et non supervisé.

- **L'apprentissage supervisé** a pour objectif de construire un modèle capable de prédire une propriété d'un élément, appelée son étiquette ou *target*, en utilisant diverses caractéristiques connues de l'élément. (Wainberg et al. 2018)

Dans cet apprentissage supervisé, il existe une certaine vérité de base qui est utilisée pour entraîner les algorithmes. (Zaharchuk et al. 2018)

- En revanche, en ce qui concerne **l'apprentissage non supervisé**, aucun critère d'images ou de classification standard n'est utilisé. C'est l'ordinateur lui-même qui doit déterminer les réponses souhaitées.

- Notre sujet portera essentiellement sur une branche spécifique de l'apprentissage automatique : **l'apprentissage profond**.

En effet, ce dernier est une véritable révolution dans le domaine de l'intelligence artificielle. Nous avons choisi d'utiliser ce type d'IA car il est novateur, perfectible et sera certainement une nouvelle révolution de notre monde après l'ère industrielle et informatique que nous avons connu lors des 2 derniers siècles.

L'apprentissage profond est le composant le plus récent et celui qui connaît la croissance la plus rapide dans le domaine de l'apprentissage automatique. Il s'agit d'un processus par lequel de vastes bases de données sont analysées, puis comparées à des vérités de base connues. (Grewal et al. 2018)

Il est récemment devenu la forme dominante de l'apprentissage automatique, en raison de la convergence des avancées théoriques, de la disponibilité de logiciels libres et d'un matériel doté d'une puissance de calcul suffisante. L'excitation actuelle dans le domaine de l'apprentissage profond provient de nouvelles données suggérant son excellente performance dans une grande variété de tâches. Il s'est avéré être une solution robuste pour des tâches telles que la classification d'images, la segmentation d'images, le traitement du langage naturel, la reconnaissance vocale et la génomique.

(Bizopoulos et Koutsouris 2019)

L'apprentissage profond est construit autour du développement de réseaux de neurones artificiels (RNA) qui permettent de catégoriser automatiquement des ensembles de données et favorisent l'apprentissage des caractéristiques contenues dans les données via des réseaux neuronaux convolutifs multicouches. (*CNN pour convolutional neural network*) (Orhan et al. 2020)

Le premier neurone artificiel a été proposé par McCulloch et Pitts et possède une ou plusieurs entrées binaires (active/inactive) et une sortie binaire. Le neurone artificiel active simplement sa sortie lorsque le nombre de ses entrées actives dépasse un certain seuil. On l'appelle aussi communément neurone formel.

Il s'agit d'un neurone binaire, c'est-à-dire dont la sortie vaut 0 ou 1. Pour calculer cette sortie, le neurone effectue une somme pondérée de ses entrées (qui, en tant que sorties d'autres neurones formels, valent aussi 0 ou 1) puis applique une fonction d'activation à seuil : si la somme pondérée dépasse une certaine valeur, la sortie du neurone est 1, sinon elle vaut 0. (Géron 2019)

Les CNN visent à simuler l'architecture du cerveau humain, en traitant les données à l'aide d'une série de neurones interconnectés.

Le système d'apprentissage profond est une méthode d'apprentissage automatique supervisé et est basé sur des réseaux neuronaux qui imitent le mécanisme des neurones humains. (Zaharchuk et al. 2018)

Ces réseaux de neurones artificiels (RNA) sont devenus progressivement assez différents de leurs cousins biologiques.

Ainsi certains chercheurs préfèrent éviter l'analogie et changer certains termes.

Par exemple « unité » à la place de « neurone ».

Ces RNA sont polyvalents, puissants et extensibles, ce qui les rend parfaitement adaptés aux tâches d'apprentissage automatique extrêmement complexes comme la classification de milliards d'images. (Wainberg et al. 2018)

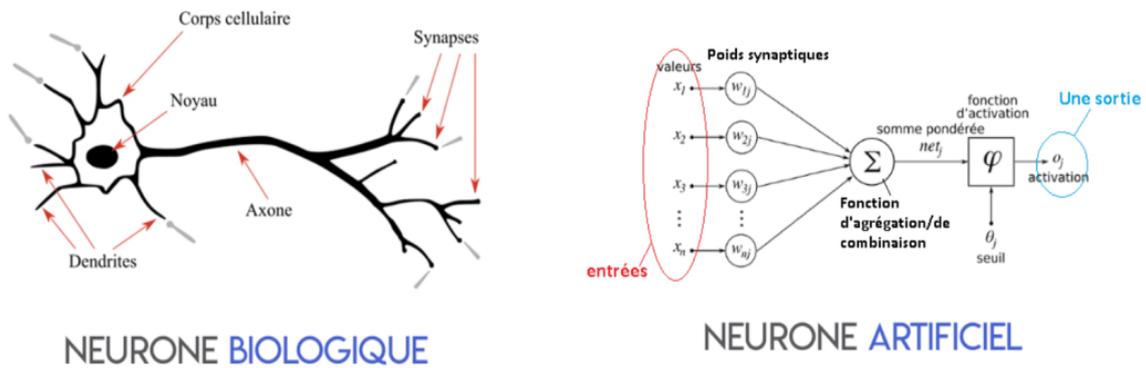


Figure 3 : Différence neurone biologique et neurone artificiel
(Maurice 2018)

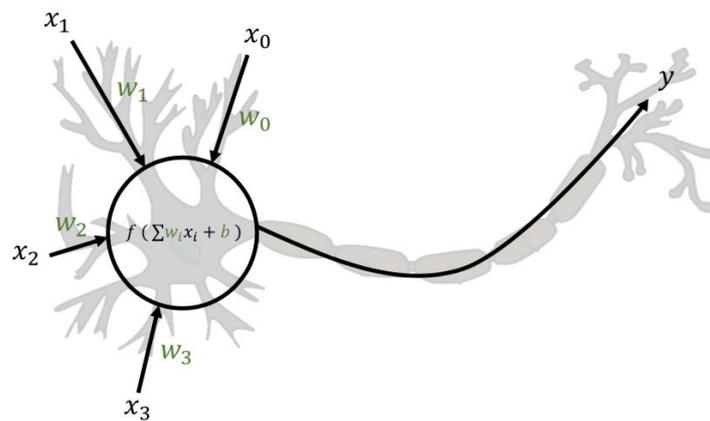


Figure 4 : Schéma d'un neurone informatique superposé à un schéma de neurone biologique (Rousseau et Douarre 2021)

Les réseaux neuronaux sont des modèles d'apprentissage automatique composés de couches empilées d'unités neuronales. Les unités neuronales combinent un modèle linéaire d'entrées, de poids correspondants et d'un terme de biais avec une fonction non linéaire.

Dans un réseau neuronal à action directe, l'information est transmise à travers le réseau de la première couche (entrée) à la dernière couche (sortie).

Les réseaux neuronaux spécialisés sont les CNN, qui appliquent des opérations de convolution pour extraire des caractéristiques telles que des bords, des coins, des tâches, des formes, des structures macroscopiques et des motifs à partir de données d'image.

Au cours de la dernière décennie, plusieurs architectures de réseaux neuronaux ont été proposées, et sont entraînés sur de grands ensembles de données de référence comme *ImageNet* et beaucoup d'entre eux ont été mis à la disposition de la communauté scientifique. (Schwendicke et al. 2020)

L'exemple le plus simple d'architecture de RNA est le perceptron.

Ce perceptron se fonde sur un neurone artificiel appelé **unité logique à seuil** (TLU, *Threshold Logic Unit*) ou parfois **unité linéaire à seuil** (LTU, *Linear Threshold Unit*).

Les entrées et les sorties sont à présent des **nombres** (à la place des valeurs binaires, actif/inactif) et chaque connexion en entrée possède un poids. (Géron 2019)

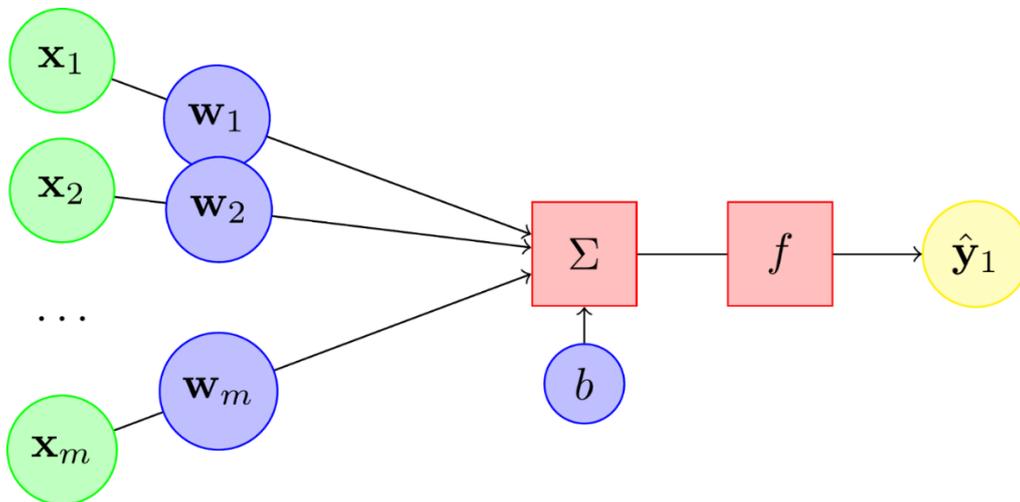


Figure 5 : Architecture du réseaux des neurones artificiels du perceptron (Chatelain et Herault 2021)

Ici sur la figure 5 :

- Des **entrées**, notées **x** sous formes de vecteurs
- Une **sortie**, notée **y**
- Des **paramètres**, notés **w** et **b**, influençant le fonctionnement du neurone. Avec **w** pour « *weight* » indiquant le **poids** donné à l'entrée et **b** correspondant au biais.
- Une **fonction d'activation** noté **f** qui transforme une valeur arbitraire en une valeur utilisable.

L'équation type de ce perceptron est donc : $\hat{y} = f(\langle \mathbf{w}, \mathbf{x} \rangle + b)$

L'algorithme d'entraînement du perceptron de Rosenblatt se fonde largement sur la règle de Hebb perçue dans son ouvrage *The Organization of Behavior* publié en 1949. Hebb suggérait que si un neurone biologique déclenche souvent un autre neurone, alors la connexion entre ces deux neurones se renforce.

Autrement dit, le poids d'une connexion entre deux neurones tend à augmenter lorsqu'ils s'activent simultanément.

Les perceptrons sont entraînés à partir d'une variante de cette règle qui prend en compte l'erreur commise par le réseau lorsqu'il réalise une prédiction : la règle d'apprentissage du perceptron renforce les connexions qui aident à réduire l'erreur.

Pour chaque neurone de sortie qui produit une prédiction erronée, il renforce les poids des connexions liées aux entrées qui auraient contribué à la prédiction juste.

Le perceptron multicouche est constitué d'une couche d'entrée, d'une ou plusieurs couches de TLU appelées couches cachées et d'une dernière couche de TLU appelée couche de sortie.

Lorsqu'un RNA possède un grand nombre de couches cachées, on parle de réseaux de neurones profonds (RNP) ou en anglais *Deep Neural Network* (DNN).

Le domaine de l'apprentissage profond étudie les RNP et plus généralement les modèles qui comprennent des piles de calcul profondes. Toutefois, de nombreuses personnes parlent d'apprentissage profond dès que des réseaux de neurones entrent en jeu même s'ils manquent de profondeur.

1.2. Les réseaux de neurones profonds

L'apprentissage profond se caractérise donc par la présence de plusieurs couches cachées de neurones.

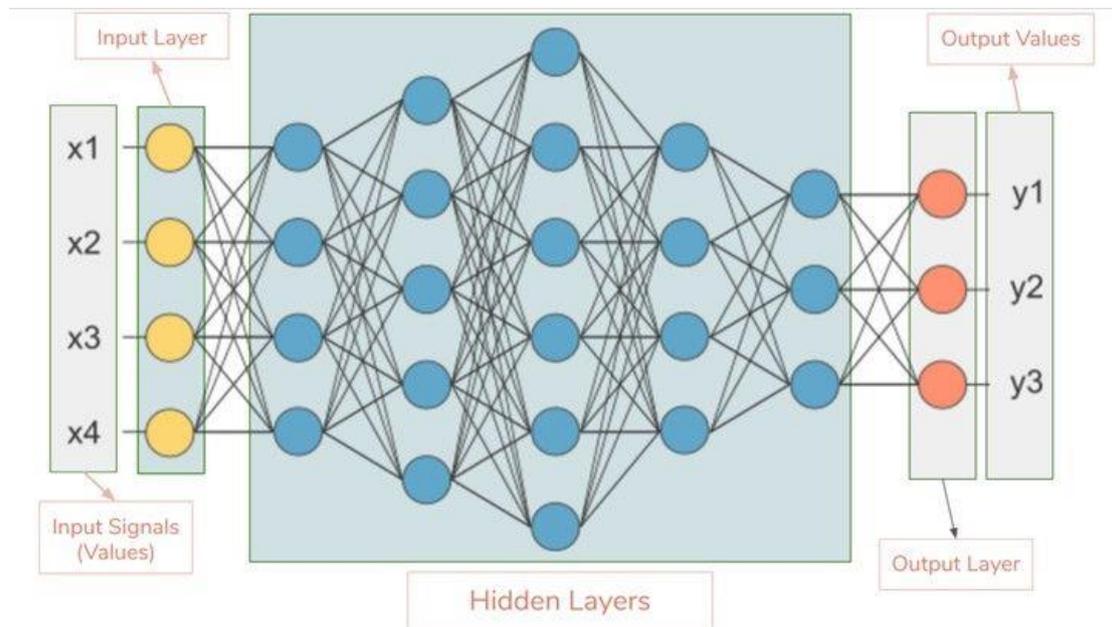


Figure 6 : Exemple de réseaux de neurones profonds (Ahirwar 2017)

Sur cette figure 6, nous avons une schématisation simplifiée d'un RNP.

- En jaune, nous avons les couches d'entrées (*inputs layers*)
- En bleu, nous avons les couches cachées (*hidden layers*)
- En rouge, nous avons les couches de sorties (*outputs layers*)

Ici, chaque symbole rond (jaune, bleu ou vert) désigne un neurone. Ainsi, nous pouvons voir sur cet exemple qu'il y a 4 neurones d'entrées, 22 neurones cachés sur 5 couches cachées, et 3 neurones de sortie.

A noter, qu'une valeur est associée aux différents neurones d'entrées et de sorties.

(Noté ici x_1 , x_2 , x_3 , x_4 , y_1 , y_2 , y_3)

Notre sujet et notre expérimentation parle de réseaux de classification, c'est-à-dire que notre réseau de neurone doit in fine reconnaître sur une radiographie rétro-alvéolaire une structure histologique ou anatomique. Il y a aura autant de couches de sorties (*output layers*) que de classes différentes (carie, émail, restauration, os par exemple). Chaque neurone de sortie possèdera une valeur $\hat{y}(i)$.

Ainsi vulgairement, nos observations \mathbf{x} sont transformées en scalaire, puis rentrent dans les neurones. Ces observations sont enregistrées comme un signal pour le réseau et peuvent être de n'importe quelle nature (des observations chiffrées, des pommes, etc.). Cela dépend de ce que l'on cherche. On a des sommes pondérées avec une fonction d'activation. Notre signal va se propager à l'intérieur de notre réseau jusqu'à notre couche de sortie.

On récupère un vecteur qu'on passe dans une **fonction d'activation softmax** qui va nous transformer ce vecteur de sortie de réseau en vecteur de probabilité. Cette fonction s'assurera que toutes les probabilités estimées se trouvent entre 0 et 1 et que leur total est égal à 1 (ce qui est obligatoire si les classes sont exclusives). Puis on va utiliser une deuxième fonction **ARGMAX** qui va nous permettre de récupérer le numéro de la classe ayant la plus forte probabilité.

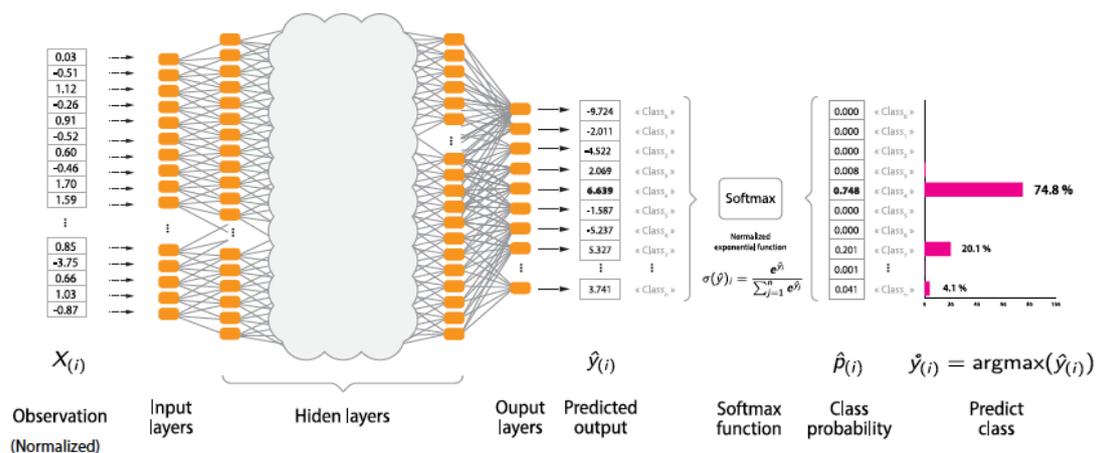


Figure 7: Réseau de neurones profonds pour classification (Université Grenoble Alpes - Supports Fidle)

Notre ensemble d'observation \mathbf{x} va rentrer dans ce réseau de neurones et faire des sommes pondérées afin de nous fournir un résultat $\hat{\mathbf{y}}$ qui est une prédiction.

Dans un apprentissage supervisé, on détient la valeur attendue \mathbf{y} qui est la réalité.

De nouvelles notions très importantes rentrent en compte : La **fonction d'erreur**, la **descente de gradient** et la **rétropropagation (Backpropagation)**.

A partir de ces deux valeurs, on va pouvoir calculer une fonction d'erreur qui va nous permettre de calculer un gradient. Et à partir de ce gradient, on va pouvoir mettre à jour notre réseau de neurone.

Ainsi, nos lots de données corrigées vont revenir alimenter le réseau de neurone et améliorer la précision et diminuer notre fonction d'erreur. Le réseau va se forger, et s'améliorer de lui-même.

Chaque cycle (Observation, réseau de neurone, valeur obtenue/valeur attendue, fonction d'erreur, gradient, correction) est appelé **itération** (*epoch*).

L'algorithme que les réseaux de neurones utilisent pour mettre à jour leurs poids (ou coefficients de réseaux) s'appelle **la rétropropagation du gradient de l'erreur**.

Les caractéristiques extraites, simples si on les considère dans les premières couches, se complexifient peu à peu au fil des opérations faites par les couches. C'est cette dimension de couches empilées, qui permet la création de caractéristiques complexes, à laquelle on fait référence lorsqu'on parle d'apprentissage « profond ».

C'est précisément la puissance des réseaux de neurones convolutifs : ils sont capables d'identifier de manière autonome les éléments discriminants d'une image en s'ajustant au problème donné. Par exemple, lorsque la tâche consiste à distinguer les chats des chiens, les caractéristiques automatiquement définies peuvent inclure des informations sur la forme des oreilles ou des pattes.

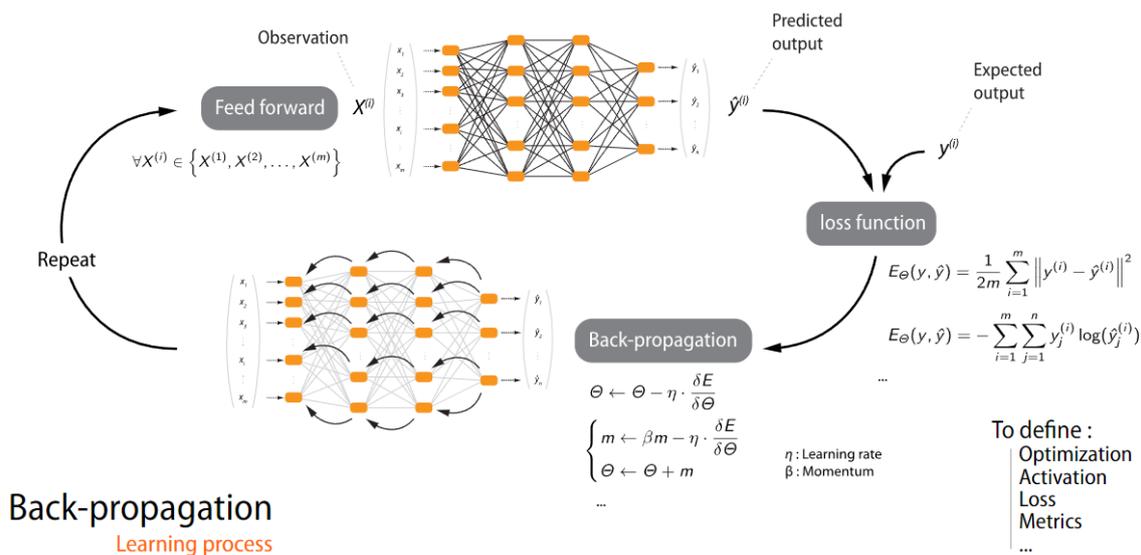


Figure 8 : Réseau de neurones profonds avec rétropropagation en fonction d'erreur (Université Grenoble Alpes - Supports Fidle)

La limite au réseau de neurones est le surapprentissage avec un risque de surentrainement appelé *overfitting*. Ce phénomène dégrade la performance des algorithmes car il manque de capacité de généralisation.

1.3. Analyse d'image par apprentissage profond

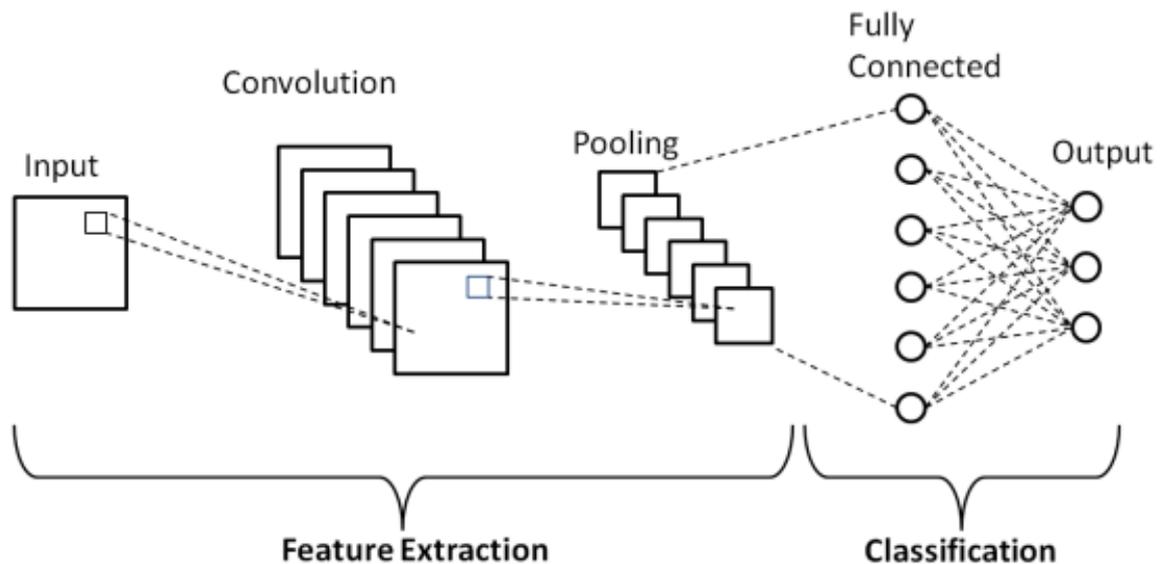


Figure 9 : Architecture schématique d'un réseau de neurone profond
(Boone et al. 2023)

1.3.1. La couche de convolution

La **convolution** est une opération mathématique simple généralement utilisée pour le **traitement et la reconnaissance d'images**.

Dans cette architecture, la première phase consiste en la convolution de l'image que nous cherchons à classifier. La convolution consiste à mettre en évidence certaines caractéristiques soigneusement sélectionnées de l'image source, créant ainsi une image similaire mais avec une sorte de filtre appliqué. Cette opération est effectuée en appliquant une matrice prédéfinie à la matrice source de l'image d'origine. Il convient de noter qu'il existe plusieurs matrices de convolution, chacune visant un aspect spécifique de l'image. Au cours de cette première phase, plusieurs filtres de

convolution sont appliqués à l'image d'origine, générant ainsi plusieurs images distinctes avec des caractéristiques de forme différentes.

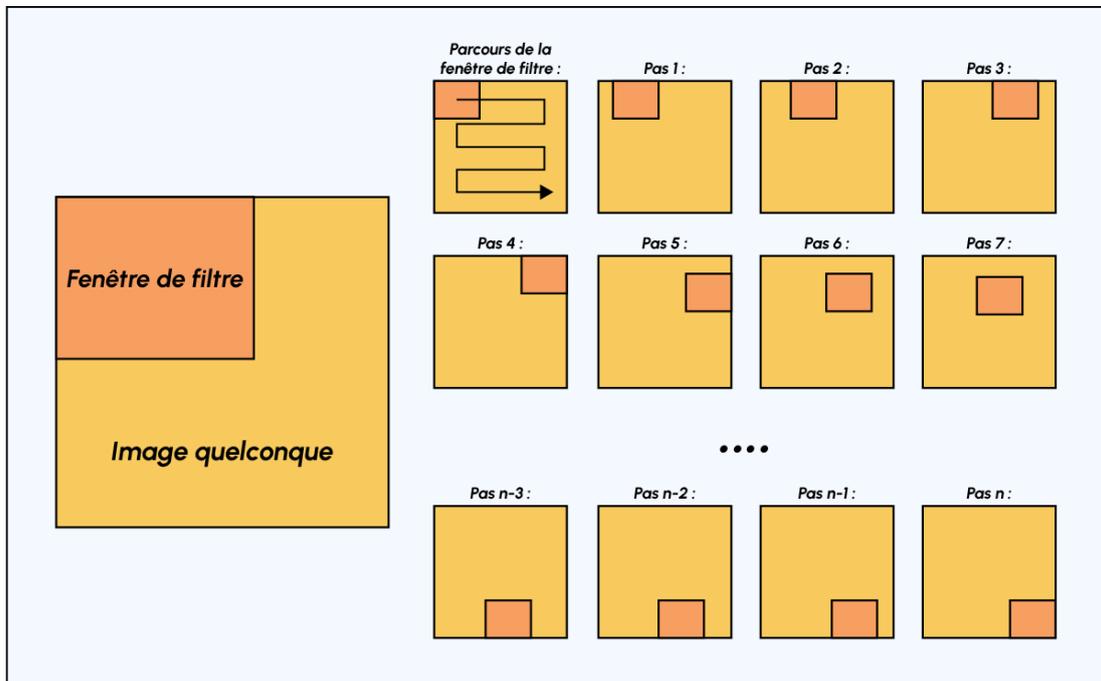


Figure 10 : Schéma du parcours de la fenêtre de filtre sur l'image
(Convolutional Neural Network ou réseaux de neurones convolutifs 2020)

Ces couches ont pour fonction d'extraire des informations et des caractéristiques de l'image. Elles utilisent des filtres pour identifier des formes, et au fur et à mesure de leur progression, elles sont capables de repérer des formes de plus en plus élaborées. Par exemple, dans la première couche, les filtres mettent en évidence des courbes simples, des traits et des pixels. La couche suivante, en utilisant les informations des filtres précédents, apprend à reconnaître des combinaisons de courbes et de traits, permettant ainsi la détection de formes plus complexes. Ce processus se répète jusqu'aux couches supérieures, qui sont capables de reconnaître des objets tels que des visages, pour n'en citer qu'un exemple.

Le rôle de cette première couche est d'**analyser les images fournies en entrée** et de **détecter la présence d'un ensemble de *features***. On obtient en sortie de cette couche un ensemble de *features maps*.

1.3.2. La couche de pooling

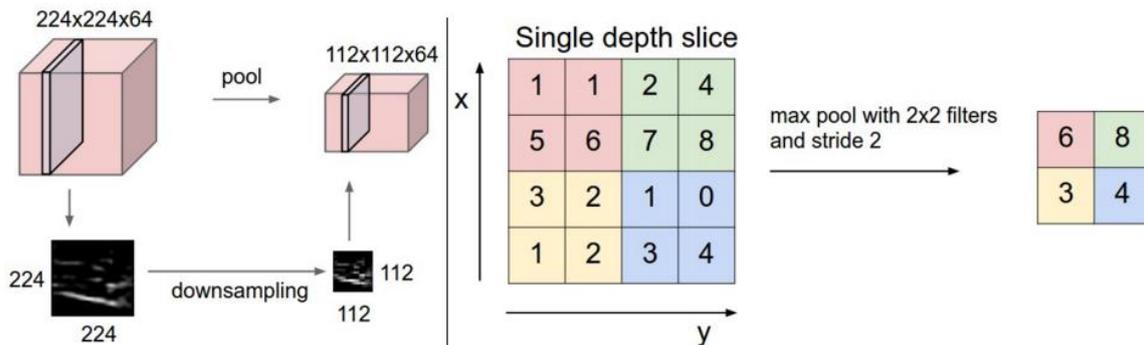


Figure 11 : Processus (à droite) et exemple d'effet (à gauche) du Max Pooling (Deep Learning Part 2)

Les couches de convolution peuvent être suivies de couches de regroupement (*pooling*).

Ce type de couche est souvent placé entre deux couches de convolution : elle reçoit en entrée plusieurs *feature maps*, et applique à chacune d'entre elles l'opération de *pooling*.

Une couche de *Max pooling*, agit comme une couche de réduction. Elle divise l'image en blocs et ne garde que le maximum de chaque bloc. Cette étape permet de réduire la taille des images d'entrées, de réduire la charge de travail en diminuant les paramètres du réseau et donc la charge de calcul, tout en gardant les principales caractéristiques de l'image. On obtient en sortie le même nombre de *feature maps* qu'en entrée, mais celles-ci sont bien plus petites.

Le but de cette étape est de garder le maximum d'informations pertinentes même en réduisant les dimensions. Cela se passe via une fenêtre, qui va glisser pas à pas sur l'ensemble de l'image, et récupérer seulement certaines valeurs de l'image.

Les fonctions de *pooling* les plus utilisés sont :

- Le *max pooling* : en prenant le maximum des valeurs de pixels de la région analysée par cette fenêtre
- Le *average pooling* : en prenant une moyenne des valeurs de pixels (cf. figure 11)

Finalement, on obtient en sortie de cette couche de *pooling*, le même nombre de *feature maps* qu'en entrée mais considérablement compressées.

Les étapes de *convolution* et de *pooling* sont ensuite itérées autant de fois que nécessaire jusqu'à ce que toutes les caractéristiques de l'image soient classifiées. Les couches de *convolution* et de *pooling* possèdent en effet des **hyperparamètres**, c'est-à-dire des paramètres dont on doit préalablement définir la valeur.

1.3.3. Les hyperparamètres

Ces hyperparamètres peuvent être ajustés pour trouver la combinaison optimale pour entraîner le réseau de neurones sur les données d'entraînement et améliorer ses performances sur les données de test.

Voici quelques exemples d'hyperparamètres couramment utilisés lors de la création d'un réseau de neurones en *deep learning* :

1. Taux d'apprentissage (*learning rate*) : Détermine la vitesse à laquelle les poids du réseau de neurones sont ajustés pendant l'apprentissage.
2. Nombre d'*epochs* : Détermine le nombre de fois que l'ensemble des données sera passé à travers le réseau de neurones pendant l'apprentissage.
3. Taille du lot (*batch size*) : Détermine le nombre d'exemples d'entraînement qui sont utilisés pour calculer la perte (*loss*) et mettre à jour les poids du réseau de neurones à chaque étape d'apprentissage.
4. Fonction d'activation : Détermine la fonction mathématique utilisée pour transformer les sorties des neurones dans chaque couche du réseau de neurones.
5. Nombre de couches et de neurones : Détermine la structure du réseau de neurones, c'est-à-dire le nombre de couches de neurones et le nombre de neurones dans chaque couche.
6. Régularisation : Détermine la quantité de régularisation appliquée aux poids du réseau de neurones pour éviter le surapprentissage (*overfitting*) aux données d'entraînement.
7. Optimiseur : Détermine l'algorithme utilisé pour optimiser les poids du réseau de neurones pendant l'apprentissage.
8. Initialisation des poids : Détermine la méthode utilisée pour initialiser les poids du réseau de neurones avant l'apprentissage.

(Pérez-Enciso et Zingaretti 2019)

1.3.4. La couche fully connected

L'étape des couches entièrement connectées (*fully connected*) équivaut simplement à l'application d'un réseau de neurones conventionnel à l'ensemble des caractéristiques.

1.3.5. Exemple d'analyse d'image par apprentissage profond

Nous allons comprendre l'analyse d'image par apprentissage profond dans le cadre d'une classification car elle est l'une des applications les plus utilisées.

La classification : L'objectif de cette phase réside dans la catégorisation des images entrantes en différentes classes, en se basant sur les caractéristiques extraites tout au long des couches de *convolution* et de *pooling*, au moyen de couches de neurones entièrement connectés. Par exemple, pour identifier un chien, ces couches mettront en évidence des caractéristiques telles que la présence de 4 pattes ou de poils, tandis qu'elles réduiront l'importance des caractéristiques associées à d'autres classes, comme la présence de plumes.

Les CNN peuvent extraire automatiquement les caractéristiques des images en utilisant les informations originales des pixels et sont fréquemment utilisés pour l'imagerie dentaire. (Yasa et al. 2020)

- **Comment se passe l'analyse d'image par apprentissage profond ?**

On cherche ici à concevoir un algorithme qui reconnaît automatiquement une image, ici l'exemple d'un chien. Le modèle est alimenté par des images labélisées ou étiquetées.

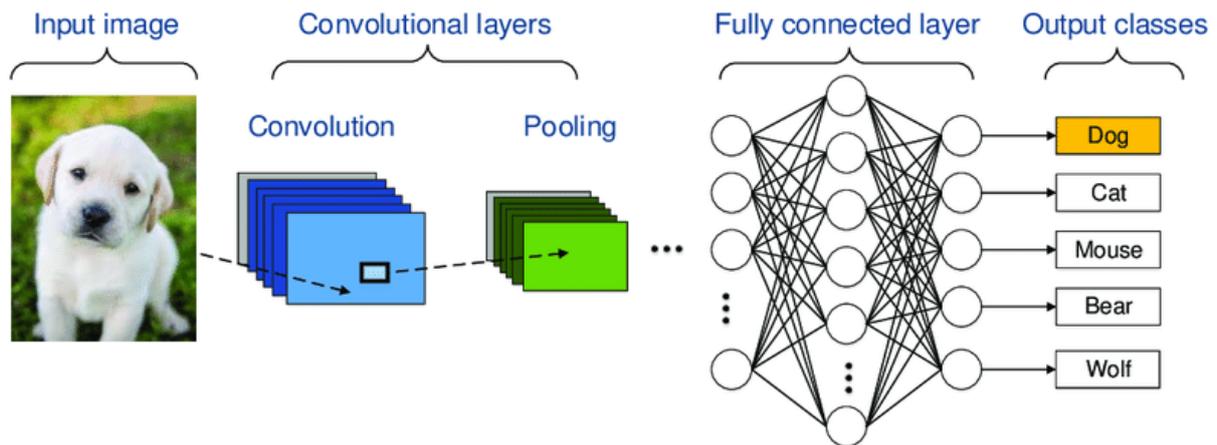


Figure 12 : Etapes de l'analyse d'image par apprentissage profond
(Ghaffari et Savaria 2020)

Notre image de chien va passer dans la couche de convolution avec application de filtres puis dans la couche de *pooling* pour réduire la charge de calcul.

Puis, cette image va rentrer dans notre réseau de neurones profonds à proprement parler (vu dans la partie 1.2).

Enfin, nous aurons une classification de l'image : d'un chien si elle est juste.

De façon un peu plus précise : La première étape s'appelle l'extraction de caractéristiques qui consiste en l'extraction de petits détails.

Elle est effectuée par des filtres qui reconnaissent par exemples des bords, des angles ou encore un pixel bleu, puis le stocke dans une base intermédiaire. Cette base intermédiaire a d'autres filtres qui reconnaissent des éléments plus gros, ronds, carrés, et autres, jusqu'à des structures plus complexes : patte de chien ou museau par exemple.

Pour chaque image, il sera ainsi associé toute une liste de caractéristiques.

L'étape suivante, de classification attribue un poids à chacune des caractéristiques précédemment retrouvées en fonction des catégories finales (chien, chat, souris) : le perceptron fait la somme des toutes ces informations.

Enfin, lors de l'entraînement du modèle, ces différents poids sont ajustés en temps réel par retro propagation.

1.4. Historique

- 1943
 - Les RNA sont décrits pour la première fois par le neurophysiologiste Warren McCulloch et le mathématicien Walter Pitts.
 - Dans leur article fondateur, ils ont présenté un modèle informatique simplifié du fonctionnement combiné des neurones biologiques du cerveau des animaux dans le but de résoudre des calculs complexes à l'aide de la logique propositionnelles. Il s'agit de la première architecture de RNA.
- 1950
 - Des scientifiques imaginent des machines pensantes
 - Le mathématicien Alan Turing publie un article intitulé « machine de calcul et intelligence ». Il décrit dans cet article comment savoir si une machine s'approche d'une IA.
 - Création du Test de Turing : Méthode qui est un jeu de délimitation.
 - Début de l'intelligence artificielle.
- 1956
 - Essor de l'IA stimulé par le début de l'informatique.
 - Conférence de *Dartmouth* : Atelier scientifique de 1956 qui est considéré comme l'acte de naissance de l'IA en tant que domaine de recherche autonome.
- 1957
 - Invention du perceptron par le psychologue Frank Rosenblatt. Il s'agit du premier programme d'apprentissage grâce à un réseau de neurone simple.
- 1965
 - Joseph Weizenbaum du MIT, développe le programme informatique ELIZA qui consiste à remplacer le psychothérapeute pendant un entretien thérapeutique.

- Ce programme sera le premier à réussir le test de Turing (seulement pendant quelques minutes)
- La fin des années 1960 marquera « l'hiver de l'IA » car les désillusions scientifiques s'accumulent, les progrès s'effondrent et les investissements s'écroulent. Les premières questions éthiques émergent.
- 80's
 - Intérêt revient pour le connexionnisme (étude des réseaux de neurones)
 - Renaissance de l'IA avec l'arrivée de nouveaux investissements. C'est la période des synthèses d'experts.
 - Mais fin des années 1980, nouvelle crise dû à l'émergence des ordinateurs personnels orientant le financement dans l'informatique classique.
- 1986
 - David Rumelhart, Geoffroy Hinton et Ronald Williams, publient un article révolutionnaire dans lequel ils introduisent un algorithme d'entraînement à rétropropagation, toujours employé aujourd'hui.
- 90's
 - D'autres méthodes d'apprentissage apparaissent comme les machines à vecteurs de support (SVM)
 - En 1997, c'est la première fois que l'IA bat le champion d' monde de l'époque Kasparov avec Deep Blue
 - Renaissance du connexionnisme : Yann Lecun a réalisé l'une des premières avancées significatives en appliquant cette approche à la reconnaissance des codes postaux lors de son travail à *AT&T Bell Labs* (Lecun *et al.*, 1989). Il a ainsi « inventé » la technique de convolution. À l'aide d'une base de données fournie par l'US Postal Service, il a réussi à entraîner un réseau multicouche pour reconnaître les chiffres du code postal imprimés sur les colis.

- Après les années 2000
 - Emergence du Big Data avec :
 - Quantité de données absolument gigantesque pour entraîner RNA
 - Augmentation extraordinaire de la puissance de calcul
 - Algorithmes d'entraînement améliorés
 - RNA dans un cercle vicieux vertueux de financement et de progrès

1.5. Utilisation en santé

Récemment, les systèmes basés sur l'intelligence artificielle (IA) qui utilisent des algorithmes profonds (DL) avec des réseaux convolutifs (CNN), ont rapidement remplacé les systèmes de détection ou de diagnostic assistés par ordinateur créés par la méthodologie traditionnelle qui utilise des traits caractéristiques abstraits par des observateurs humains.

Les soins de santé et la médecine en général ont tout à gagner de l'apprentissage profond en raison du volume considérable de données générales et de la prolifération croissante des dispositifs médicaux et des systèmes d'enregistrement numérique.

(Esteva et al. 2019)

Par conséquent, il est raisonnable de considérer l'IA comme un outil pouvant aider les praticiens.

De nombreuses études récentes montrent que l'apprentissage profond a la capacité d'effectuer des interprétations complexes au niveau des spécialistes de la santé.

Ainsi, les principaux acteurs de la recherche sur l'IA se sont engagés sur le marché mondial de la santé connectée il y a plusieurs années maintenant. Les **GAFAM** (Google, Apple, Facebook, Amazon, Microsoft) et leurs homologues chinois **BATX** (Baidu, Alibaba, Tencent, Xiaomi), ont déjà massivement investi dans le domaine de la santé connectée. Les masses de données obtenues à partir de projets de santé

connectée aident en retour à éduquer les algorithmes d'apprentissage automatique, rendant ainsi les programmes de plus en plus efficaces et précis.

Grâce à l'énorme quantité de données analysées, il est probable que dans un avenir proche, les études cliniques sur l'IA seront statistiquement plus puissantes et plus fiables que les études « classiques » même randomisées à double insu. (PetitPas et al. 2021)

1.5.1. En médecine

De nos jours, les applications médicales de l'IA incluent, sans toutefois s'y limiter, la radiologie, la dermatologie, la neurologie, l'ophtalmologie, l'oncologie, la cardiologie, la génétique, les soins d'urgence, la conception de médicaments. (PetitPas et al. 2021)

Nous pouvons ainsi lister plusieurs spécialités médicales où l'usage de l'intelligence artificielle est utilisée et est un avantage dans le diagnostic.

1.5.1.1. En ophtalmologie

L'ophtalmologie est à l'aube d'une révolution dans le dépistage, diagnostic et gestion des maladies oculaires.

Les ophtalmologues utilisent l'IA pour l'aide au diagnostic concernant les cataractes nucléaires, les glaucomes, les dégénérescences maculaires (DMLA) et les rétinopathies diabétiques.

Les moyens :

- Les ophtalmologistes s'appuient sur l'imagerie OCT (Tomographie à cohérence optique) du nerf optique. Ainsi, une méthode hybride de DL utilisant un seul OCT à large champs a permis de classer avec succès les suspects de glaucome en bonne santé des glaucomes précoces en créant une carte de de probabilité dont la précision était de 93,1% par rapport au diagnostic d'un expert en glaucome, surpassant les paramètres actuels de l'OCT.

(Muhammad et al. 2017)

- Une étude récente sur la DMLA a utilisé efficacement un CNN profond pour classer la DMLA à partir de photos du fond de l'œil. (Treder et al. 2018)

La recherche du segment antérieur a démontré la capacité de DL à classer les cataractes nucléaires à partir d'images transversales de lampe à fente sur le système de classement de Wisconsin par rapport aux classificateurs professionnels. (Gao et al. 2015)

Des études ont été menées sur le diagnostic de la rétinopathie diabétique via des images de fond de l'œil avec une excellente sensibilité.

(Tsiknakis et al. 2021)

Les résultats :

- Le diagnostic précoce de ces maladies permettra de réduire la perte de vision évitable.
- L'apprentissage profond permettra aux ophtalmologistes de concentrer leur temps sur les relations avec les patients ainsi que sur l'optimisation des soins médicaux et chirurgicaux.

(Grewal et al. 2018)

1.5.1.2. En cardiologie

- Détection des plaques d'athérome dans les coronaires par observation de caractéristiques faciales associées. Par exemple, l'alopécie, les cheveux gris, les rides du visage, le pli du lobe de l'oreille, le xanthélasma ou encore le gérontoxon se sont révélés être probablement associés à un risque accru de coronaropathie et à une mauvaise santé cardiovasculaire. Tous ces signes cliniques sur une photographie faciale serviraient à enrichir notre réseau de neurones.

(Lin et al. 2020)

- L'apprentissage profond est actuellement exploité dans le domaine de la cardiologie dans le traitement du signal par détection de la fibrillation atriale (FA). Cette pathologie est associée à un risque élevé d'accident vasculaire cérébral alors qu'elle est très souvent asymptomatique, ce qui rend sa détection difficile.

- Les « *smart watch* » sont des dispositifs de mesure de la fréquence cardiaque qui sont évidemment des outils très prometteurs car ils permettraient une détection en continu de la fréquence cardiaque et du temps en fibrillation atriale (FA). Ainsi, on débiterait une anticoagulation dès que des critères de risque embolique sont présents et ainsi traiter les patients au coup par coup, « *pill in the pocket* », avec une durée d'anticoagulation courte.
- L'utilisation de l'apprentissage profond dans le domaine de l'imagerie médicale est très prometteuse. Les modalités d'imagerie comme le CT-scan, l'échocardiographie et l'imagerie par résonance magnétique (IRM) cardiaque peuvent fournir de riches données pour entraîner des réseaux de neurones. Toutefois, pour que ces algorithmes puissent apprendre efficacement et aider les médecins, il est essentiel d'avoir des données labélisées avec une valeur à prédire connue, comme la fraction d'éjection mesurée par échocardiographie. Les algorithmes peuvent alors apprendre à calculer automatiquement la fraction d'éjection et s'approcher du "*gold standard*" avec une meilleure vitesse et fiabilité. De plus, certaines études ont montré que des modèles de Deep Learning basés sur plus de 14 000 échocardiographies sont plus performants que les médecins pour détecter certaines cardiomyopathies. (Kusunose et al. 2019)

L'analyse du CT-scan coronaire peut également bénéficier de l'IA, avec des algorithmes qui permettent de calculer la fraction de réserve de flux (FF) le long d'une artère coronaire en quelques secondes, ce qui est beaucoup plus rapide que les méthodes traditionnelles. (Muller et al. 2022)

1.5.1.3. En radiologie

La radiologie diffère des autres applications de reconnaissance d'images des algorithmes de DL en ce sens qu'un examen de tomographie assistée par ordinateur ou d'IRM peut se composer de milliers d'images, et non d'une seule. Cela augmente considérablement la complexité des algorithmes de calcul nécessaires.

Les images en radiologie peuvent varier considérablement, en fonction des facteurs et des pathologies du patient, ce qui augmente encore la complexité du problème.

Actuellement, la plupart des applications en radiologie sont étroitement axées sur la réalisation d'une tâche spécifique. Le domaine d'intérêt actif en radiologie peut être divisé en plusieurs catégories différentes : détection de lésions ou de maladies, classification et diagnostic, segmentation et quantification. (McBee et al. 2018)

Au vu du nombre d'utilisation du DL en radiologie, on peut citer pêle-mêle quelques indications sourcées comme :

- Un système très précis et entièrement automatisé de détermination de l'âge des os a été mis au point avec un temps d'interprétation de moins de 2 secondes. (Lee et al. 2017)
- Un CNN avec cinq couches convolutionnelles qui a pu atteindre un taux de précision de 85,5 % pour la classification des maladies pulmonaires interstitielles. (Anthimopoulos et al. 2016)
- Plusieurs applications différentes ont montré que le DL est très efficace pour identifier les nodules pulmonaires.
- Les algorithmes de DL se sont avérés très efficaces pour segmenter automatiquement l'anatomie du cerveau. (Akkus et al. 2017)

Les outils d'IA peuvent être utilisés comme un outil complémentaire pour confirmer/valider les doutes et les décisions des radiologues.

1.5.1.4. En oncologie

- L'apprentissage profond peut avoir un impact sur l'oncologie clinique lors du diagnostic, du pronostic et du traitement. Les domaines spécifiques de l'oncologie clinique dans lesquels l'apprentissage profond est prometteur comprennent le cancer d'origine inconnue, le sous-typage moléculaire des cancers, le pronostic et la capacité de survie, ainsi que l'oncologie de précision. Des exemples d'applications de l'apprentissage profond dans chacun de ces domaines sont énumérés. Les modalités des données utilisées par les modèles d'apprentissage profond sont nombreuses et comprennent les catégories de données génomiques (simple gène, méthylation, microbiome), transcriptomiques (Séquence d'ARN, puce à ADN) et histopathologiques (Immunohistochimie) couvertes dans cette étude. L'IA a le potentiel de

transformer radicalement les soins du cancer et de les rapprocher de la promesse de **l'oncologie de précision**. (Tran et al. 2021)

- La création de vastes bibliothèques de lames numériques à grande échelle, telles que l'Atlas du Génome du Cancer (TCGA), a permis aux chercheurs d'accéder librement à des ensembles de données richement conservées et annotées d'images pathologiques liées à des résultats cliniques et à des informations génomiques. Cela a favorisé des recherches significatives dans le domaine de l'intelligence artificielle appliquée à la pathologie numérique et à l'oncologie.(Jiang et al. 2020)
- Dans le domaine de la santé, et en particulier pour l'analyse d'images médicales, l'apprentissage profond à l'aide de CNN a été utilisé avec succès dans des systèmes d'aide au diagnostic, par exemple pour détecter le cancer du sein lors de mammographies (Becker et al. 2017), le cancer de la peau lors de dépistages cliniques de la peau. (Esteva et al. 2017)
- En outre, les lectures d'histopathologie du cancer, qui nécessitent des experts humains pour scanner et diagnostiquer laborieusement des images de plusieurs giga pixels (ou des lames physiques de taille équivalente) peuvent être complétées par des CNN entraînés à détecter les cellules mitotiques (Cireşan et al. 2013) ou les régions tumorales. Ils peuvent être entraînés à quantifier la quantité de PD-L1 présente dans une image histopathologique - une tâche importante pour déterminer le type de médicament immuno-oncologique auquel un patient serait réceptif. (Esteva et al. 2019)

1.5.1.5. En dermatologie

- Un CNN développé pour classer les lésions cutanées (carcinomes kératinocytaires vs kératoses séborrhéiques bénignes, et mélanomes malins vs naevus bénins) a atteint des performances équivalentes à celles des dermatologues. (McBee et al. 2018)

1.5.1.6. En génétique

- D'ores et déjà, les modèles d'apprentissage profond peuvent prédire, avec plus ou moins de succès, comment les variations génétiques modifient les

processus cellulaires impliqués dans la pathogenèse, quelles petites molécules moduleront l'activité de protéines pertinentes sur le plan thérapeutique et si des images radiographiques sont révélatrices d'une maladie. (Wainberg et al. 2018)

- Les chercheurs ont obtenu une AUC de 89 % en utilisant un algorithme de DL pour identifier automatiquement les chromosomes en métaphase à l'aide d'images de microscopie à balayage. (McBee et al. 2018)

1.5.1.7. En chirurgie

La robotique est un sous-domaine spécifique de l'IA. Elle vise à augmenter l'autonomie des machines en les dotant de capacités perceptuelles, décisionnelles et d'action.

- Robot assisté par ordinateur
- Prothèses intelligentes
- Robots d'assistance aux personnes

(Intelligence artificielle et santé · Inserm, La science pour la santé)

1.5.2. En odontologie

Parmi les diverses fonctions de l'apprentissage profond, les fonctions de détection et de classification d'objets sont fréquemment appliquées à la radiographie. La fonction de détection d'objets permet de détecter la position d'objets spécifiques dans une image. La fonction de classification peut diviser automatiquement divers objets en certaines catégories fixes. Ces fonctions se sont avérées efficaces pour la détection et la classification de maladies et d'états tels que les caries, la sinusite maxillaire, la morphologie inhabituelle des racines, l'ostéoporose présumée, les fractures verticales de racines, et les lésions radioclares. (Kuwada et al. 2020)

1.5.2.1. Détection de lésions carieuses

Diverses études ont montré une précision importante dans la détection de lésions carieuses.

Ainsi les réseaux neuronaux convolutifs ont été appliqués pour détecter les lésions carieuses et péri-apicales avec des précisions d'acceptable à élevées.

Également, pour détecter les lésions carieuses sur les radiographies *bitewing*, un réseau neuronal profond s'est montré significativement plus précis que les dentistes. (Cantu et al. 2020)

Ainsi, nous pouvons voir que sur l'étude menée en 2021 par Lee et al, un modèle de réseau de neurone (U-Net) a été utilisé dans la détection des caries par radiographies de type bitewing. Les performances diagnostiques du modèle CNN sur l'ensemble des données de test étaient les suivantes : VPP : 63,29 % ; Sensibilité : 65,02 % ; et score F1, 64,14 %, ce qui montre des performances assez précises. Cependant, le taux de fausse détection des caries dentaires était légèrement plus élevé lorsque la qualité des radiographies était faible et que le chevauchement dentaire était important.

Lorsque les trois dentistes ont détecté des caries en utilisant les résultats du modèle CNN comme données de référence, la performance diagnostique globale des trois cliniciens s'est considérablement améliorée, comme le montre l'augmentation du ratio de sensibilité. (Lee et al. 2021)

La détection des lésions carieuses par apprentissage profond nous montre des résultats prometteurs. En effet, dans une étude de 2022, Li et al, ont observé une distinction automatique des caries dentaires avec une sensibilité de 0,835 par le modèle d'apprentissage profond. Ce score est nettement supérieur au score d'un jeune dentiste.

Lorsque les experts ont été assistés par l'apprentissage en profondeur, leurs performances diagnostiques ont augmenté, avec une meilleure précision et un accord inter-observateur amélioré. (Li et al. 2022)

Des études, telles que celle de Lee et al. en 2018, ont montré d'excellents résultats pour la détection de lésion dentaire sur des radiographies rétro-alvéolaires (Lee et al. 2020). L'étude de Calegno et al. de 2019 a également montré des résultats similaires en utilisant un modèle d'apprentissage profond conçu pour la détection et la localisation des lésions dentaires sur des images de transillumination. (Casalegno et al. 2019)

Néanmoins les réseaux de neurones sont perfectibles. En effet d'après l'étude menée par Lian et al. en 2021 démontre que les performances de l'ensemble des données entraîné par deux modèles algorithmiques (nnUnNet et DenseNet121) donnent des résultats semblables avec les résultats de six dentistes experts dans les différentes métriques retenues.

L'étude portait également sur la classification de la profondeur de caries, et là encore les résultats globaux étaient relativement similaires aux dentistes experts. On peut tout de même noter un léger avantage au modèle pour les caries superficielles et un léger avantage pour les dentistes experts en ce qui concerne les caries atteignant le tiers externe de la dentine avec ou sans atteinte pulpaire. (Lian et al. 2021)

La détection des lésions carieuses repose traditionnellement sur des méthodes visuelles tactiles ou radiographiques, souvent combinées entre elles. Alors que la sensibilité de la détection visuo-tactile est limitée, notamment sur les surfaces proximales des dents postérieures, la détection radiographique a une sensibilité plus élevée mais nécessite des rayonnements ionisants. Les deux méthodes sous estiment plutôt qu'elles ne surestiment l'étendue de la lésion ; De plus, l'évaluation radiographique ne permet qu'une évaluation bidimensionnelle de structures tridimensionnelles.

1.5.2.2. La parodontite

La parodontite est une maladie inflammatoire qui peut entraîner une perte osseuse parodontale et à terme un déchaussement, ou une perte des dents, si elle n'est pas diagnostiquée et traitée correctement.

Par conséquent, la détection et la gestion précoce de la perte osseuse parodontale joue un rôle crucial dans l'amélioration du résultat clinique.

Cependant, la détection et le diagnostic de la perte osseuse sur les radiographies dentaires panoramiques sont considérés comme une tâche difficile avec un faible taux de concordance intra et inter-examineur en raison de leur structures complexes et de leur faible résolution.

Les réseaux de neurones convolutifs profonds ont récemment été adoptés dans l'analyse des images médicales avec des applications réussies pour la détection assistée par ordinateur (CADe) et le diagnostic (CADx).

Grâce à un cadre d'apprentissage en plusieurs étapes, le modèle proposé a pu atteindre un niveau de performance de détection des pertes d'os parodontales (*LBP* pour *Periodontal Bone Loss*) supérieure à celle des cliniciens. (Kim et al. 2019)

1.5.2.3. Le nombre de racines distales sur les premières molaires mandibulaires

Une étude a évalué le nombre de racines distales des premières molaires mandibulaires à l'aide d'un CBCT.

Des modèles d'apprentissage ont été créés en extrayant des patches d'images de radiographies panoramiques et en les introduisant dans des systèmes d'apprentissage profond.

Ces systèmes d'apprentissage profond ont montré des niveaux de performances élevées en différenciant si la racine distale était unique ou avec une racine supplémentaire. (Hiraiwa et al. 2019)

1.5.2.4. Les fractures verticales

Les fractures verticales de la racine sont signalées dans 3,7% à 30,8% des dents traitées par endodontie et sont principalement observées dans les prémolaires et les molaires mandibulaires. Elles constituent l'une des maladies dentaires les plus difficiles à traiter de manière conservatrice, et presque toutes les dents présentant une fracture radiculaire sont soit extraites, soit traitées par des techniques d'hémisection ou de séparation radiculaire.

En outre, les fractures verticales de la racine sont parfois identifiées de manière fortuite sur les images panoramiques. Certaines dents avaient un traitement endodontique et ne présentaient aucun symptôme (ou seulement des symptômes légers), même si une fracture verticale de la racine est présente. (Fukuda et al. 2020)

Cependant un traitement précoce impliquant la résection des racines infectées permet d'obtenir des durées de survie à 5 et 10 ans de 94% et 64% respectivement. C'est l'intérêt ici d'un réseau de neurone qui permettrait de détecter automatiquement et rapidement une fracture.

Sur l'étude de (Fukuda et al. 2020), il a été développé un modèle d'intelligence artificielle pour détecter les fractures verticales des dents sur les radiographies panoramiques. L'évaluation des performances de ce modèle a révélé une sensibilité de 0,75, une VPP de 0,93 et une mesure F1 de 0,83, montrant ainsi qu'un système de CAO pour la radiographie panoramique a du potentiel pour cette fonction particulière.

1.5.2.5. Rapport nerf mandibulaire et 3ème molaire mandibulaire

L'action combinée d'un panoramique dentaire et de l'apprentissage profond pourrait permettre d'améliorer l'évaluation du risque de blessure du nerf mandibulaire avant extraction de la dent de sagesse.

L'application des réseaux neuronaux convolutifs profonds peut améliorer significativement la fiabilité et permettre à tous les dentistes d'atteindre une précision similaire ou supérieure à celle des spécialistes expérimentés.

En outre elle pourrait réduire les efforts de diagnostic en économisant du temps d'évaluation et en permettant une documentation semi-automatisée. (Ekert et al. 2019)

1.5.2.6. La détection de lésions péri-apicales

La détection radiographique des lésions péri-apicales est sujette à de grandes variations entre les examinateurs. De plus, la capacité de discrimination dépend fortement de l'expérience des examinateurs. (Ekert et al. 2019)

La lésion péri-apicale est souvent une découverte fortuite détectée sur les radiographies rétro-alvéolaires, panoramiques ou CBCT.

Le CBCT a considérablement augmenté la détection des zones péri-apicales par rapport aux radiographies rétro-alvéolaires et panoramiques. Cela suggère que le CBCT améliore la détection des lésions osseuses péri-apicales et permet d'améliorer le diagnostic, la planification du traitement et le pronostic.

Par exemple, l'utilisation du CBCT avec un réseau de neurones associé permettrait de savoir la nature de la lésion péri-apicale (granulome, kyste) et d'adapter en conséquence le traitement. Dans certains cas, un traitement endodontique pourrait y être fait. Alors qu'une exérèse à des fins histologiques anéantirait de par son geste à tout traitement plus conservateur. (Okada et al. 2015)

Les systèmes d'IA basés sur des méthodes d'apprentissage profond peuvent être utiles pour détecter les pathologies péri-apicales sur les images CBCT pour une application clinique. (Orhan et al. 2020)

1.5.2.7. Association chirurgico-orthodontique

L'orthodontie est une spécialité de l'odontologie qui se concentre sur le diagnostic et la prévention des malocclusions ainsi que leur correction. Elle se concentre sur l'anatomie crânio-faciale et plus précisément sur les modifications de la zone dento-alvéolaire.

Le clinicien en orthodontie utilise principalement des outils de diagnostic pour prendre des décisions cliniques. L'utilisation de l'IA s'est avérée efficace et utile pour le dentiste en lui permettant d'être plus précis dans le diagnostic et la prise de décision clinique. Les résultats de différentes études suggèrent que la précision des systèmes basés sur l'IA est très prometteuse et fiable. Ces systèmes peuvent simplifier les tâches et fournir des résultats rapidement, ce qui permet au dentiste de gagner du temps et d'être plus efficace dans ses tâches.

De nouvelles technologies ont été développées, basées sur les principes de l'imitation du fonctionnement du cerveau humain. Elles sont principalement basées sur les technologies de l'intelligence artificielle (IA) qui ont apporté une contribution significative. Ces technologies automatisées ont été utilisées comme des outils puissants pour prédire le diagnostic et aider les cliniciens à planifier le traitement.

Les systèmes basés sur l'IA ont été utilisés comme des outils pour aider les orthodontistes à fournir des soins standardisés aux patients et à maximiser les chances d'atteindre les objectifs fixés. Ces outils incluent notamment :

- Des repères céphalométriques pour évaluer la position des os de la tête
- La détermination du stade de croissance et de développement des vertèbres cervicales pour aider à la planification du traitement
- L'application de l'IA pour prédire le besoin de traitement orthodontique et pour la planification du traitement
- Les modes de traitement chirurgicaux, notamment pour la fermeture des fentes, les chirurgies orthodontiques et orthognathiques, qui sont principalement destinés à améliorer l'apparence du visage ainsi que les fonctions des patients.
- L'application de l'IA pour prédire l'attractivité faciale après la chirurgie orthognathique.

(Khanagar et al. 2021)

L'utilisation de l'IA en chirurgie orthognathique est considérablement prometteuse en raison de la large diffusion de la photographie numérique et de l'imagerie médicale, ainsi que des investissements colossaux réalisés par les sociétés de recherche et de développement dans les domaines de l'orthodontie numérique et de la chirurgie robotique.

Les avantages de l'IA comprennent une amélioration de la précision du diagnostic grâce à l'imagerie maxillo-faciale améliorée par l'IA, une planification de traitement thérapeutique automatisée, la fabrication d'appareils orthodontiques et chirurgicaux sur mesure et un suivi thérapeutique efficace basé sur la superposition d'images.

L'IA permet également d'analyser et d'interpréter efficacement de nombreux paramètres, offrant ainsi une vision plus transparente et plus globale des caractéristiques physiques du patient, et pourrait être un outil de diagnostic extrêmement puissant en offrant une perception tridimensionnelle exacte et objective des caractéristiques dento-faciales.

(PetitPas et al. 2021)

1.5.2.8. En implantologie

Dans le domaine de l'implantologie, l'apprentissage profond ouvre la voie à de nombreuses opportunités. Voici quelques-unes de ses applications :

- Détection perte osseuse parodontale et péri-implantaire.
- La classification des implants : L'incapacité d'identifier le type d'implant et, par conséquent, de réutiliser l'implant à des fins prothétiques s'est avérée être la cause profonde du retrait d'environ 3 % des implants dans le monde. La plupart des modèles développés ont montré une précision souhaitable pour distinguer les systèmes d'implants dentaires et les marques. Cependant, la principale limitation était le nombre de systèmes comparés ; au plus, 12 types différents de systèmes d'implants dentaires ont été utilisés pour la formation et la classification. Considérant que le nombre de systèmes et de marques différents dans le monde dépasse 2000, les modèles actuels ne peuvent être que d'une utilité limitée.
- La détection des complications des implants dentaires, y compris la perte osseuse et la fracture de l'implant. La détection systématique de la perte osseuse précoce sur les radiographies peut favoriser une intervention précoce, et les modèles actuels ont montré une grande précision lorsqu'ils sont mesurés par rapport aux cliniciens.
- La prédiction des résultats du traitement, par exemple, pour les implants en utilisant des prédicteurs comme les paramètres de la microstructure des trabécules, la courbe de couple d'insertion, l'état de santé des patients, ou pour les dents affectées parodontales. Cependant, l'utilisation de données biologiques comme la salive et d'autres biomarqueurs pourraient être bénéfiques pour améliorer la précision de ces modèles de prédiction.

(Mohammad-Rahimi et al. 2022)

1.6. Avantages

L'utilisation de l'apprentissage profond dans une pratique courante future posséderait de nombreux atouts.

L'objectif des études en IA en radiologie est de réaliser des évaluations automatisées, routinières et simples, afin que les radiologues puissent lire les images plus rapidement et gagner du temps pour les cas plus complexes.

Cette méthode peut faire **gagner du temps** en permettant la préparation automatique de fiches dentaires et de dossiers dentaires électroniques.

Cette utilisation libérerait du temps et des ressources pour le clinicien afin de se concentrer plus sur la discussion au diagnostic, au pronostic et aux options de traitements.

Cela permet donc d'automatiser des processus chronophages pour les opérateurs humains. Par exemple, certains algorithmes peuvent automatiser la segmentation des lésions tumorales sur les images d'une tomодensitométrie, afin de planifier les traitements de radiothérapie, faisant gagner un temps considérable au radiothérapeute et limitant les risques d'erreur.

Ces algorithmes optimisent les paramètres de traitement de l'image en tenant compte des conditions d'exposition, des doses de radiation et de l'anatomie des patients. En conséquence, les images présentent un meilleur contraste, une résolution accrue et une gestion améliorée du bruit numérique.

Cette amélioration de la qualité d'image permet de réduire les doses de radiation administrées aux patients grâce à des temps d'acquisition plus courts et à des reconstructions d'images plus performantes. Les algorithmes permettent d'obtenir de meilleurs résultats avec moins d'informations. **Cette réduction des doses de radiation** élargit la portée de la tomодensitométrie (TDM) ou de la tomographie par émission de positrons (TEP) à un plus grand nombre de patients qui pourraient en bénéficier, tout en réduisant les coûts des examens. De plus, ces examens sont plus courts, ce qui les rend moins inconfortables, et le risque de mouvement et de flou est considérablement réduit.

Cela peut également aider les cliniciens travaillant dans des **zones mal desservies** (désert médicaux) ou dans des régions pauvres du globe au moyen de la télé-médecine.

Par exemple, un processus automatisé efficace de téléophtalmologie permettrait de répondre aux besoins de dépistage non satisfaits.

Les algorithmes d'apprentissage profond peuvent déjà être appliqués aux programmes de téléophtalmologie pour distinguer les images rétinienne normales des images anormales, ce qui réduit le nombre d'images examinées par le clinicien. Au fur et à mesure que la sensibilité et la spécificité des systèmes d'apprentissage profond s'améliorent, le nombre de séries d'images à examiner sera réduit, ce qui améliorera l'accès aux communautés mal desservies en minimisant le temps passé par le clinicien et en atténuant la pénurie de cliniciens. Les solutions d'apprentissage profond peuvent aider les cliniciens à identifier les anomalies présentes lors d'un test de diagnostic.

Les systèmes de diagnostic DL pourraient être intégrés dans le cadre des soins primaires, ce qui réduirait, voire éliminerait, les renvois inutiles. En poussant ces systèmes un peu plus loin, les outils de DL pourraient permettre l'autosurveillance ophtalmique par les patients via la photographie rétinienne sur smartphone, l'acuité visuelle et les tests du champ visuel. Cette technologie permettrait de responsabiliser les patients, de faciliter le diagnostic précoce et d'identifier les maladies oculaires traitables. (Grewal et al. 2018)

Des systèmes de diagnostic d'apprentissage profond pourraient être intégrés dans le cadre des soins primaires, ce qui réduiraient ou atténueraient les renvois inutiles.

Ensuite, ces systèmes d'assistance automatisés pour imageries radiographiques dentaires peuvent atténuer ou surmonter les lacunes des **examineurs moins expérimentés**.

Parfois, l'évaluation visuelle qui repose sur l'expertise et l'expérience peut être personnelle et imprécise.

Les systèmes d'apprentissage profonds pourraient aider les médecins en offrant un **2^{ème} avis comme « second lecteur »** en signalant par exemple les zones préoccupantes sur les images.

Cela permettrait d'augmenter le niveau de confiance des radiologues et la cohérence du diagnostic.

Avec cette intelligence artificielle (IA) en tant que **compagnon**, les radiologues peuvent bénéficier du soutien d'une machine performante 24 heures sur 24, 7 jours sur 7. Il s'agit d'une IA auxiliaire conçue pour aider les médecins au quotidien, sans prétendre les remplacer. Il est essentiel de se rappeler que le radiologue conserve toujours le dernier mot, car il porte la responsabilité médicale. En d'autres termes, l'IA est simplement un outil d'aide à la décision.

Cette collaboration permet d'améliorer la qualité du diagnostic médical et des examens pratiqués. La profession médicale devient plus efficace et réactive. Parmi les avantages attendus, il y a la possibilité de consacrer davantage de temps aux patients en expliquant plus en détail les résultats, les conclusions et les recommandations, y compris pour la prise en charge future.

De plus, l'intelligence artificielle facilite la détection des **urgences** médicales, comme les hémorragies intracrâniennes, par exemple. Un logiciel a été développé pour repérer automatiquement les anomalies sur les scanners, ce qui permet d'éviter les retards dus à un volume élevé d'examens ou au manque de disponibilité des radiologues.

(Bernard Nordlinger et al. 2022)

L'utilisation combinée de l'apprentissage profond et de l'imagerie médicale s'appelle la **radiomique**. Les caractéristiques radiomiques sont des mesures quantitatives dérivées de l'analyse de l'image médicale.

Par exemple la combinaison du panoramique dentaire et de l'apprentissage profond pourrait permettre l'évaluation du risque de blessure du nerf mandibulaire avant l'extraction de la 3^{ème} molaire mandibulaire.

En effet, le panoramique dentaire seul a ses limites car bidimensionnel laissant apparaître des chevauchements de structures anatomiques et des distorsions.

Le gold standard reste le CBCT mais il émet bien plus de rayons pour le patient.

Les méthodes quantitatives d'apprentissage profond offrent un large éventail de caractéristiques radiomiques riches qui ne sont souvent pas perceptibles à l'œil humain. Ces caractéristiques peuvent être utilisées pour établir des corrélations entre les caractéristiques d'imagerie et les facteurs cliniques, le diagnostic et les résultats.

Ces caractéristiques radiomiques comprennent :

- Les caractéristiques traditionnelles de taille, forme ou texture.
- L'homogénéité ou l'hétérogénéité de la lésion
- Des caractéristiques basées sur l'intensité des pixels telles que la moyenne, la variance et la distribution de l'intensité des pixels dans la lésion
- Les descripteurs d'histogrammes d'intensité d'image
- Les textures extraites des images filtrées
- Des caractéristiques fractales complexes

(McBee et al. 2018)

Ces caractéristiques peuvent ensuite être utilisées pour l'analyse quantitative de l'image médicale et pour la corrélation avec les facteurs cliniques, le diagnostic et les résultats.

Les caractéristiques radiomiques basées sur les textures ont été utiles pour prédire quels patients atteints d'un cancer de l'œsophage répondraient le mieux au traitement.

(Tixier et al. 2011)

Les caractéristiques radiomiques ont également été utilisées avec succès pour prédire les résultats cliniques et le risque de métastases à distance dans le cancer du poumon. Par exemple, (Coroller et al. 2015) ont identifié 35 caractéristiques radiomiques de cancers du poumon qui étaient utiles pour distinguer les patients présentant un risque élevé de développer des métastases à distance.

Il est à noter qu'un tel logiciel aurait la capacité d'apprendre de chaque cas concret auquel il est exposé pour améliorer ses performances dans de futurs cas. Cette notion de **progrès continu** est très avantageuse. Plus on l'utilise, plus il sera précis et juste dans l'aide et le diagnostic.

Ainsi les applications de l'intelligence artificielle en pathologie contribuent non seulement à améliorer **la précision et l'objectivité** des diagnostics, mais aussi à réduire la charge de travail des cliniciens, ce qui leur permet de consacrer davantage de temps à des tâches décisionnelles de haut niveau. (Jiang et al. 2020)

1.7. Limites

Si les promesses de l'apprentissage profond semblent illimitées, des inquiétudes subsistent. Ces inquiétudes sont fondées, car une formation inappropriée à l'apprentissage profond peut entraîner des résultats involontaires et préjudiciables.

Le premier problème rencontré est le **manque de contexte clinique**. En effet, l'une des principales limites des études comparant les performances humaines et algorithmiques est ce manque de contexte clinique, qui contraint le diagnostic à être réalisé en utilisant uniquement les images disponibles. Normalement, le lecteur humain a accès à la fois à l'imagerie médicale et à des données supplémentaires comme les antécédents du patient et son dossier médical, des tests supplémentaires, ou encore le témoignage du patient.

Le **manque de transparence** est également problématique car la plupart des méthodes d'apprentissage profond sont considérées comme une boîte noire car elles ne peuvent pas expliquer intuitivement comment les prédictions sont faites.

Il existe un consensus sur le fait que de tels outils doivent être soigneusement étudiés et interprétés avant d'être intégrés dans le système d'aide à la décision clinique. La relation entre les radiologues et les IA constituera un défi futur à relever.

Les performances de l'apprentissage profond dépendent du nombre de données, et de la qualité et biais des images d'entrée.

Le **manque relatif de données médicales** fait partie des limites rencontrées car l'apprentissage profond nécessite de grands ensembles de données d'entraînement pour obtenir des résultats de haute qualité.

Cela est particulièrement difficile avec les données médicales étant donné que la procédure d'étiquetage des données médicales est coûteuse car elle nécessite le travail manuel d'experts médicaux.

Le nœud du problème se situe au niveau du transfert de connaissances entre l'humain et la machine, transfert qui nécessite d'une part des progrès méthodologiques mais également une collaboration approfondie entre experts de disciplines différentes.

De la même façon que les biostatisticiens et les bio-informaticiens ont intégré les laboratoires de recherche médicale il y a quelques décennies, une discipline et un métier nouveaux doivent être créés, qui permettent de dépasser les collaborations interdisciplinaires actuelles et d'intégrer réellement la science des données et des connaissances dans les activités de recherche et de soin.

De plus, la plupart des données médicales appartiennent à des cas normaux (sains) plutôt qu'anormaux, ce qui les rend très déséquilibré.

Les autres défis : **Problèmes de standardisation, de disponibilité, de dimensionnalité, de volume, de qualité des données, la difficulté d'acquérir les annotations correspondantes et le bruit dans les annotations.**

Ce niveau de performance qui devrait approcher une précision de 100% pour un diagnostic automatique, n'a pas encore été atteint, et même s'il l'était, la question essentielle de savoir qui doit assumer la responsabilité des résultats du diagnostic resterait posée.

L'apprentissage profond entraîne donc obligatoirement un questionnement **éthique**. Le développement de nouvelles technologies dans le domaine médical pose des défis juridiques et réglementaires. Le remboursement des services liés à l'intelligence artificielle (IA) sera abordé de manière différente selon les marchés mondiaux où les services seront fournis. Les applications de l'IA dans l'expérience des soins médicaux sont susceptibles d'être intégrées de manière transparente dans les rencontres traditionnelles avec les patients, évitant ainsi la nécessité d'une facturation supplémentaire pour recouvrer les coûts.

Les cinq aspects clés du traitement éthique des données dans l'IA sont définis comme le consentement éclairé, la protection de la vie privée et des données, la propriété, l'objectivité et l'inégalité par rapport à ceux qui ont ou n'ont pas les ressources nécessaires pour traiter les données. Le développement et la mise en œuvre doivent être centrés sur le patient pour garantir le meilleur résultat possible. La relation de confiance entre médecin et patient ne doit pas être remise en question, même lorsqu'il y a une erreur dans l'application de l'IA. (Currie et al. 2019)

Ces défis éthiques et juridiques tournent autour de la question de savoir qui assumera la responsabilité des images si la technique d'apprentissage automatique et d'apprentissage profond effectuent l'interprétation des études.

Par exemple, si un algorithme d'apprentissage profond ne parvient pas à identifier un nodule pulmonaire, le responsable sera-t-il le fournisseur de l'algorithme ou le radiologue ?

Compte tenu de la manière dont la détection et le diagnostic assistés par ordinateur ont toujours été traités sur le plan juridique, il s'agirait probablement du radiologue. Toutefois, cela pourrait changer à mesure que les algorithmes d'apprentissage profond jouissent d'une plus grande indépendance et autonomie en matière d'interprétation des images médicales.

Bien que les algorithmes d'apprentissage profond se soient révélés très prometteurs dans une variété de tâches en radiologie et en médecine dans son ensemble, ces systèmes sont loin d'être parfaits. Les réseaux neuronaux peuvent être statistiquement impressionnants, mais individuellement peu fiables et peuvent faire des erreurs que les humains ne feraient pas.

Tableau 1 : Avantages et inconvénients de l'apprentissage profond

| Avantages | Inconvénients |
|--|--|
| Gain de temps pour le clinicien | Une formation inappropriée à l'apprentissage profond peut entraîner des résultats involontaires et préjudiciables |
| Améliorer précision et objectivité du diagnostic | Manque de contexte clinique |
| Deuxième avis comme « second lecteur » | Questionnement éthique |
| Aide aux cliniciens inexpérimentés | Données médicales (Problèmes de standardisation, de disponibilité, de dimensionnalité, de volume, de qualité des données, la difficulté d'acquérir les annotations correspondantes et le bruit dans les annotations) |
| Aide à l'imagerie médicale via la radiomique | Procédure d'étiquetage des données médicales est coûteuse car elle nécessite le travail manuel d'experts médicaux. |
| Faciliter la détection des urgences | « Boîte noire » sans explication concrète |
| IA compagnon : Une machine performante, œuvrant 7 jours sur 7 et 24 heures sur 24. Une IA auxiliaire, qui aide le médecin au quotidien, sans avoir la prétention de le remplacer | Transfert de connaissance entre l'humain et la machine |
| Œil humain peu performant et fatigable | |
| Les algorithmes vont contrôler les paramètres de l'image | |
| Doses de rayonnement reçus par le patient sont plus faibles | |

1.8. Applications futures

Il existe de nombreuses applications futures potentielles de l'apprentissage profond en radiologie, dans lesquelles pratiquement tous les aspects de l'interprétation des images pourraient être utilisés.

Un exemple concret d'application future de l'utilisation de l'apprentissage profond en matière de prévention et dépistage pourrait être illustré par deux exemples concrets d'études menées par (de Koning et al. 2020) et (Reduced Lung-Cancer Mortality with Low-Dose Computed Tomographic Screening 2011).

Pour le cancer du poumon, les deux études susmentionnées démontrent un bénéfice net du dépistage chez les patients à haut risque en termes de survie. Le scanner à faible dose est l'outil de dépistage le plus efficace, comparé à la radiographie thoracique simple, avec une faible dose de radiation. Ces résultats pourraient probablement conduire à des programmes de dépistage de masse organisés au niveau national, ce qui entraînerait inévitablement une importante quantité d'imagerie à interpréter et une surcharge de travail pour les radiologues. Pour faciliter ce processus, l'assistance à la détection des nodules par ordinateur pourrait être la piste la plus prometteuse. Ainsi, l'utilisation de l'apprentissage profond pourrait faciliter et accélérer le travail de détection et de diagnostic des radiologues.

En outre, les applications futures comprennent le traitement automatique des données, les nouvelles applications diagnostiques, le pronostic, le suivi automatisé des résultats d'imagerie et la génération automatique de rapports préliminaires

Deux théories futures possibles s'affrontent :

La théorie avec une **intelligence artificielle forte** et de remplacement qui dit que la crainte que des machines puissent potentiellement remplacer les médecins humains dans un avenir proche doit être prise au sérieux, car la dynamique de changement dans le domaine de la recherche sur l'IA est sans précédent.

Cependant, la plupart des experts supposent que les humains devront coopérer avec ce que l'on appelle une **intelligence artificielle faible** pendant au moins quelques décennies. Il est presque impossible que l'IA remplace les radiologues dans les

décennies à venir, mais les radiologues utilisant l'IA remplaceront inévitablement les radiologues qui ne le font pas.

La théorie avec cette IA faible permettra aux radiologues d'atteindre une précision accrue avec une plus grande efficacité. Ainsi, nous devons également plaider pour la création de réseaux interconnectés d'identification des données de patients du monde entier et former l'IA à grande échelle en fonction des différentes données démographiques des patients, des zones géographiques, des maladies, etc.

Ce n'est que de cette manière que nous pourrions créer une IA qui soit socialement responsable et qui profite à un plus grand nombre de personnes.

Certains envisagent que les applications médicales de l'IA pourraient éventuellement remplacer les médecins, que ce soit pour répondre aux besoins médicaux dans les zones sous-médicalisées ou pour trier les patients et les orienter vers les soins appropriés. Cependant, l'utilisation de ces logiciels par le grand public sans supervision médicale soulève d'importantes questions éthiques. Ce système réduit la relation entre le patient et le médecin à un acte purement technique, laissant le patient livré à ses interrogations et à ses inquiétudes.

De plus, il existe un véritable risque que le médecin renonce à son rôle au profit de la machine, croyant que celle-ci sait mieux que lui. Il pourrait être amené à suivre une décision qui ne serait pas la sienne et découvrir ultérieurement que la machine s'est trompée. Pour éviter cette situation, le médecin, en tant que seule personne habilitée à poser un diagnostic, doit conserver son autonomie face à la machine. Il doit être en mesure de comprendre pourquoi et comment les décisions sont prises par l'IA, et avoir la capacité de les contourner si nécessaire.

C'est en associant IA et médecin que les performances sont les plus impressionnantes, supérieures aux deux pris isolément.

2. RADIOGRAPHIE RETRO-ALVEOLAIRE ET LESION DENTAIRE

2.1. La carie dentaire

La carie dentaire est l'une des maladies chroniques les plus répandues dans le monde. Les individus sont susceptibles d'être atteints de cette maladie tout au long de leur vie tant sur les dentures primaires que permanentes, et peuvent endommager la couronne dentaire et, plus tard dans la vie, les surfaces radiculaires exposées. Les caries dentaires se forment par une interaction complexe au fil du temps entre des bactéries productrices d'acide et des glucides fermentescibles, et de nombreux facteurs de l'hôte, notamment les dents et la salive.

Le risque de carie comprend des facteurs physiques, biologiques, environnementaux, comportementaux et liés au mode de vie, tels qu'un nombre élevé de bactéries cariogènes, un flux salivaire inadéquat, une exposition insuffisante au fluor, une mauvaise hygiène buccale, des méthodes d'alimentation inappropriées pour les nourrissons et la pauvreté.

Le premier modèle expliquant l'étiologie de la carie dentaire a été proposé par Keyes en 1960. Ce dernier a identifié trois facteurs causals interreliés : un hôte susceptible, des bactéries cariogènes et des glucides fermentescibles. Le facteur temps a été ajouté au diagramme original par Newbrun en 1978.

En effet, l'interaction entre les trois facteurs doit avoir lieu durant une certaine période pour que la carie se développe.

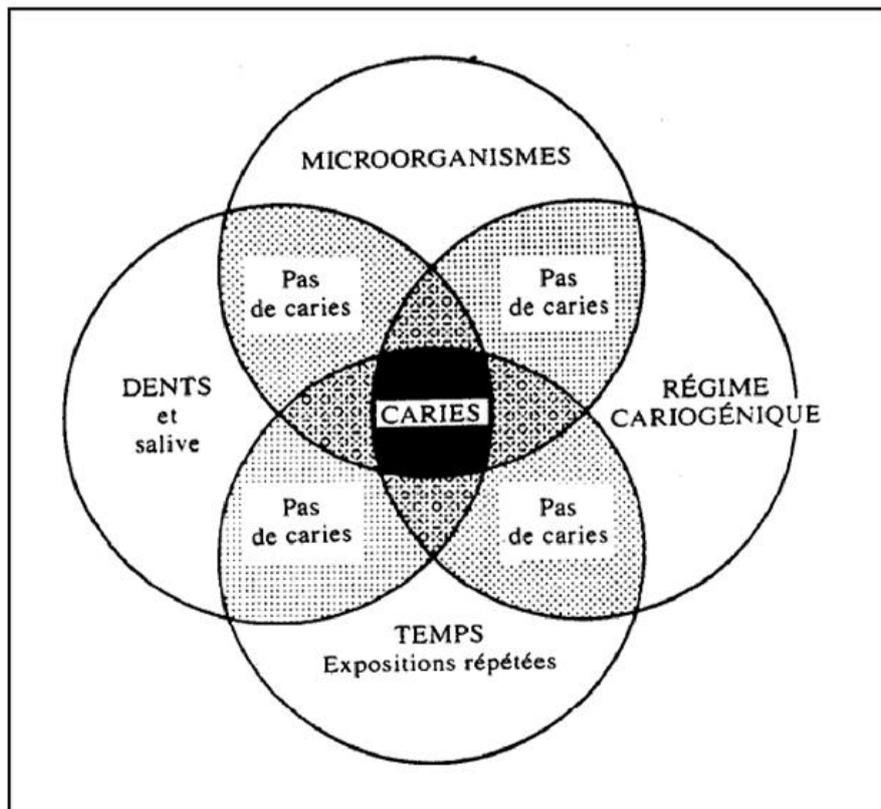


Figure 13 : Schéma de Keyes modifié par Newbrun (Danielle et al. 2014)

La maladie se développe à la fois dans les couronnes et les racines des dents, et elle peut apparaître dans la petite enfance sous la forme d'une carie agressive qui affecte les dents primaires des nourrissons et des jeunes enfants. L'approche de la prévention primaire doit être basée sur les facteurs de risque communs. La prévention et le traitement secondaire doivent se concentrer sur la gestion du processus carieux au fil du temps pour chaque patient, avec une approche peu invasive et préservant les tissus. (Selwitz et al. 2007)

La carie dentaire est une maladie dynamique multifactorielle, induite par le biofilm, induite par le sucre, qui entraîne la déminéralisation et la reminéralisation phasiques des tissus dentaires durs. L'équilibre entre les facteurs pathologiques et protecteurs influence l'initiation et la progression des caries. Cette interaction entre les facteurs sous-tend la classification des individus et des groupes en catégories de risque carieux, permettant une approche de soins de plus en plus adaptée. La carie dentaire est une maladie inégalement répartie et évitable avec des charges économiques et de qualité de vie considérables. L'utilisation quotidienne de dentifrice

au fluorure est considérée comme la principale raison du déclin global des caries dans le monde au cours des dernières décennies.

(Pitts et al. 2017)

2.2. La radiographie rétro-alvéolaire

2.2.1. Définitions et généralités

Les radiographies sont un élément important du diagnostic dentaire. La radiographie péri-apicale est une technique d'imagerie. Les radiographies péri-apicales fournissent des informations importantes sur les dents et l'os environnant. Le film montre l'ensemble de la couronne et de la racine des dents, ce qui fournit des informations essentielles pour aider au diagnostic des maladies dentaires les plus courantes, notamment la carie dentaire, les abcès dentaires et la perte osseuse parodontale. D'autres résultats importants peuvent être détectés, notamment l'état des restaurations, la présence de tartre, de dents incluses ou de fragments de dents cassées et les variations de l'anatomie des dents et des os.

Les radiographies péri-apicales peuvent être prises pour n'examiner que certaines zones, ou elles peuvent être prescrites comme une série complète de radiographies de la bouche. Une série complète de radiographies de la bouche fournit des images de toutes les dents et est généralement composée de 20 films, dont 4 radiographies *Bitewing* et 16 radiographies péri-apicales.

2.2.2. Indications

Pour l'opérateur, le placement du film est assez simple et rapide. Les radiographies rétro-alvéolaires jouent un rôle essentiel dans le diagnostic et la gestion de divers problèmes dentaires, notamment pour :

- Détecter les infections et lésions péri-apicales.
- Identifier les caries et évaluer leur gravité.
- Examiner les structures endodontiques et la vitalité pulpaire.
- Évaluer la position des racines dentaires avant une extraction.

- Diagnostiquer les parodontites et la perte osseuse.
- Investiguer les douleurs dentaires lorsque l'examen clinique est insuffisant.
- Suivre les implants dentaires.
- Détecter les traumatismes et fractures dentaires.
- Surveiller les dispositifs prothétiques et bridges.
- Évaluer la présence et la taille de kystes dentaires.
- Suivre l'éruption des dents chez les enfants.
- Planifier l'extraction ou le traitement des dents de sagesse.

(Kamioner 2023)

2.2.3. Limites

- Le niveau d'os parodontal est mal représenté
- Peu reproductible
- L'ombre du processus zygomatique recouvre la racine des molaires maxillaires
- Les angles horizontaux et verticaux doivent être évalués pour chaque patient
- Cette technique nécessite un opérateur expérimenté
- Un site horizontal d'angulation entraîne un chevauchement de la couronne et de la racine
- Une angulation incorrecte verticale provoque un raccourcissement ou un allongement de l'image
- Les racines des prémolaires et des molaires maxillaires sont raccourcies
- La couronne des dents est souvent déformée ce qui empêche la détection des caries proximales
- Si le rayon central n'est pas dirigé vers le centre du film, il peut en résulter une coupe conique

(Poorterman 2015)

2.2.4. Visualisation des structures anatomo-pathologiques

La détection des lésions carieuses sur une radiographie intra-buccale se manifeste par l'observation d'une zone radio-claire dans l'émail, la dentine ou le cément suite à leur déminéralisation provoquée par l'acide produit par les bactéries présentes dans le biofilm.

Cette zone d'ombre radio-claire se présente généralement sous forme de cavité en forme de soucoupe.

Cette zone radio-claire peut être partiellement plus radio-claire que le tissu d'origine sain adjacent indiquant la présence d'autre tissus superposés dans l'axe de la radiographie, elle peut aussi être entièrement radio-claire, caractérisant la disparition de l'intégralité du tissu à ce niveau et selon l'axe de la radiographie.

Sur des caries arrêtées, il est possible d'observer en radiographie une fine ligne radio-opaque le long des contours de la déminéralisation, résultant de la formation de dentine tertiaire en réponse à l'agression. (Whaites et Drage 2019)

3. EXPERIMENTATION

3.1. Matériels et méthodes

Cette étude a été approuvée par la faculté d'odontologie de Nancy, faisant partie de l'université de Lorraine. Cette étude consiste en la création d'un réseau de neurone convolutif capable de segmenter automatiquement des caries sur 46.

Les clichés radiologiques rétro-alvéolaires utilisés dans cette étude ont été sélectionnés dans une base de données, sans extraction d'informations privées des patients, telles que le nom, le sexe, l'âge, l'adresse, ou les numéros de téléphone.

Tous ces clichés ont été obtenus à des fins de diagnostic et de traitement ordinaires. Ces données ont été collectées au cabinet du Dr Manuel FATTET à Neufchâteau (88) avec son accord.

Un jeu de données, contenant des clichés radiographiques dentaires, a été collecté et séparé pour former un ensemble de données d'entraînement, un ensemble de données de validation et un ensemble de données de test.

Nous avons pu recueillir 576 radiographies rétro-alvéolaires de la dent n°46 pour la segmentation.

La segmentation a été effectuée à l'aide du logiciel *SuperAnnotate*. Un contact avec un ingénieur en solution d'intelligence artificielle a été pris. Leur rôle est de travailler sur le développement, l'implémentation et la gestion de solutions basées sur l'IA.

Ainsi, ma demande pour utiliser leur plateforme a été acceptée et j'ai pu utiliser leur site pour effectuer ma segmentation manuelle.

La segmentation manuelle d'images est une technique qui consiste à découper une image en zones de pixels appartenant à une même **classe** d'objets appelé aussi **label**.

C'est-à-dire qu'une labellisation de chaque élément sur la radiographie doit être faite.

Une fois la segmentation finie, nous avons en possession notre jeu de données qui a ensuite été séparé. Puis le réseau de neurone a été construit et nous a permis d'avoir des résultats.

3.2. Logigramme

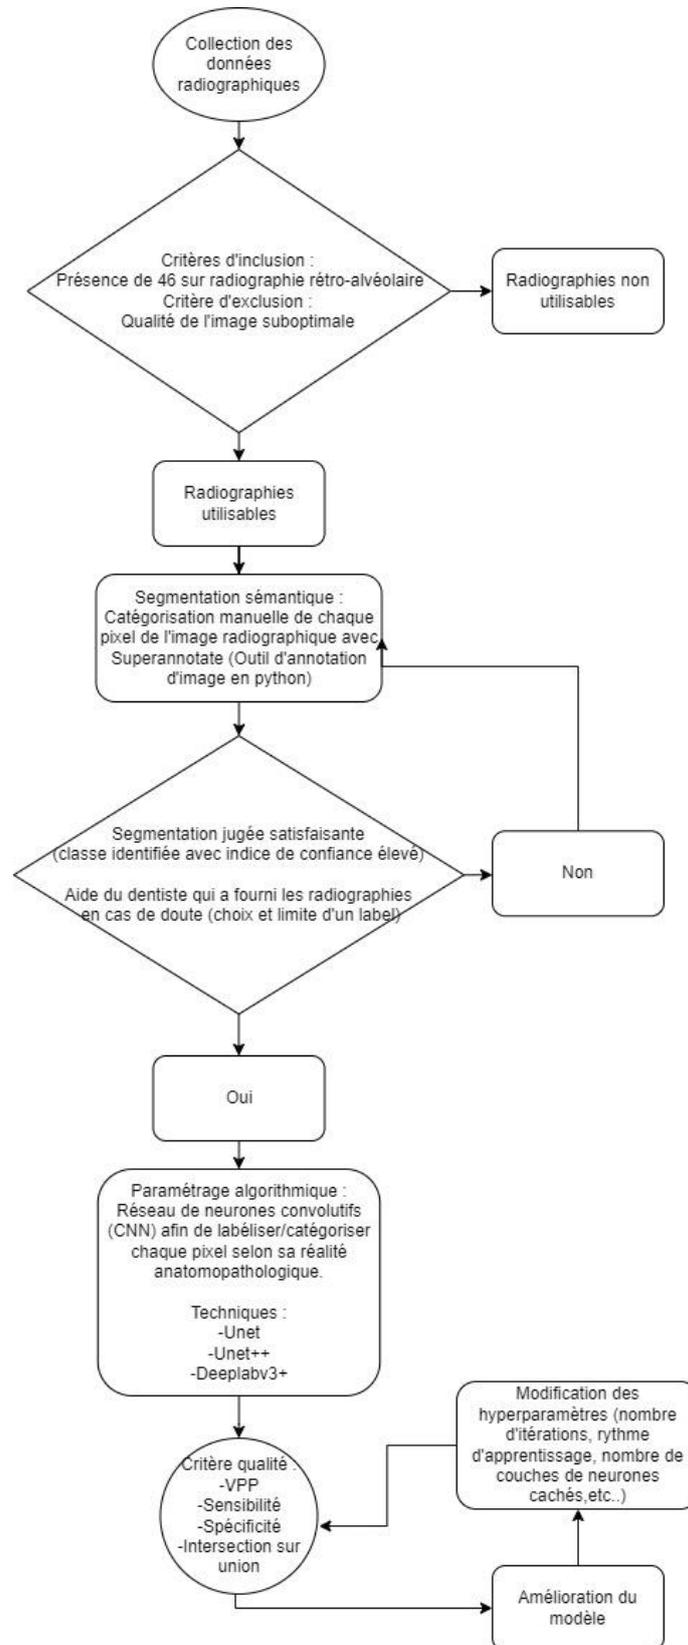


Figure 14 : Diagramme synthétique de l'expérimentation
(Source personnelle)

3.3. Récolte et tri des données

Un total de 12217 clichés radiographiques dentaires a été collecté et séparé au cabinet du Dr FATTET.

Les radiographies ont été obtenues à l'aide d'un générateur *Kodak carestream 220* et d'un générateur *dürrdental VistaIntra*. Le scanner radiographique est un *pspix sopra d'Acteon*.

Tout d'abord un tri a été effectué pour ne garder que les radiographies rétro-alvéolaires des premières molaires mandibulaires (46).

Ces clichés devaient répondre à différents critères de sélection et d'inclusion :

- Le cliché devait être une radiographie rétro-alvéolaire faite avec un angulateur
- La dent n°46 devait être visible en entier
- La qualité de radiographie devait être jugée comme bonne (pas de flou, pas d'artefacts)

Ainsi, 576 radiographies rétro-alvéolaires de la dent n°46 ont été choisies pour la segmentation.

3.4. Segmentation des données

3.4.1. Définitions/Généralités

La segmentation a été faite à l'aide du logiciel *SuperAnnotate*.

Simplement nous avons différents types de segmentation :

- La segmentation binaire
- **La segmentation multi classe**
- La segmentation multi label

Notre expérimentation ici est une segmentation multi classe.

La segmentation manuelle d'images est une technique qui consiste à découper une image en zones de pixels appartenant à une même classe d'objets.

C'est-à-dire qu'une labellisation de chaque élément sur la radiographie doit être faite.

Sur les 576 clichés rétro-alvéolaires gardés à l'issue de la première étape de tri, seul 546 ont été segmentés. Les 30 clichés éliminés n'ont pas été gardés pour diverses raisons. En effet, la radiographie pouvait être de bonne qualité, mais les limites des différents labels étaient difficiles à juger. Par exemple, une superposition de plusieurs classes rendait compliquée la segmentation.

Une fois la segmentation des 546 clichés rétro-alvéolaires finie, nous avons en notre possession notre jeu de données.

3.4.2. Stratégie de labellisation par opérateur

La segmentation des labels a été effectuée par l'utilisation de polygones dont les coordonnées X et Y des différents points sont sauvegardées. J'ai procédé seul à la segmentation, hormis pour certains cas concernant le choix ou la limite de certaines classes. Dans ces cas-là, j'ai demandé l'avis du Dr Fattet pour affirmer ou infirmer le label. L'avantage inhérent à cette segmentation individuelle réside dans le maintien de la cohérence avec les critères établis. Ce processus évite les variations dues à des interprétations subjectives. Cependant, il est important de souligner que la principale contrainte est le temps considérablement investi dans cette segmentation et l'efficacité relativement limitée qu'engendre le fait de travailler en solitaire.

Par soucis de temps et d'efficacité, les labels contenus sur les dents coupées sur la radiographie n'ont pas été segmentés.

Par exemple, si une 44 possédant un traitement endodontique est coupée sur l'image, la segmentation de ces labels « 44 » et « traitement endodontique » n'a pas été faite.

3.4.3. Choix des labels

Afin de permettre l'analyse algorithmique des images, une étape de labélisation (ou étiquetage ou segmentation) des différents éléments visibles a dû être réalisée.

Étant donné l'objectif d'identification des caries sur la 46, nous nous sommes focalisés sur les éléments histologiques, anatomiques et morphologiques.

Nous avons défini les labels suivants :

- Numéro des dents de 41 à 48
- Email

- Dentine
- Pulpe
- Cément
- Desmodonte
- Os mandibulaire
- Nerf mandibulaire
- Restauration d'obturation
- Restauration prothétique
- Restauration endodontique
- Carie
- Crampon pour champ opératoire
- Tenon
- Angulateur
- Foramen mentonnier
- LIPOE

Les labels n'ayant pas été assez segmentés n'ont pas été pris en compte dans l'algorithme. Par exemple les labels de numérotation des dents 41.42.43.44.45.46.47.48 et les labels histologiques dentine et cément.

On visualise ci-dessous :

- Le nombre d'annotations par classe
- Le nombre d'images par classe
- Le nombre d'annotations présentes sur chaque image

Certaines classes sont peu représentées (en termes d'images présentes). Les classes présentes dans moins de 40 images ne sont pas conservées. Les classes d'instances de certaines dents ne sont pas conservées : elles font l'objet d'un autre problème (soit segmentation des dents par type, soit segmentation multi label).

On remarque néanmoins que la dent la plus annotée est la 46, annotée dans 440 images sur les 546. Les dents adjacentes 45 et 47 sont également très souvent annotées.

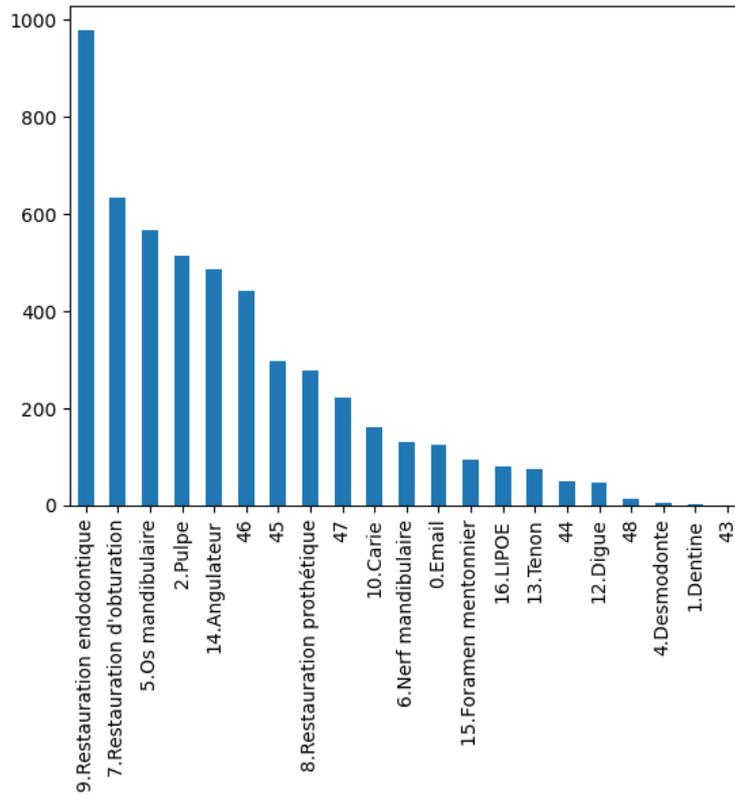


Figure 15 : Nombre d'annotations par classe

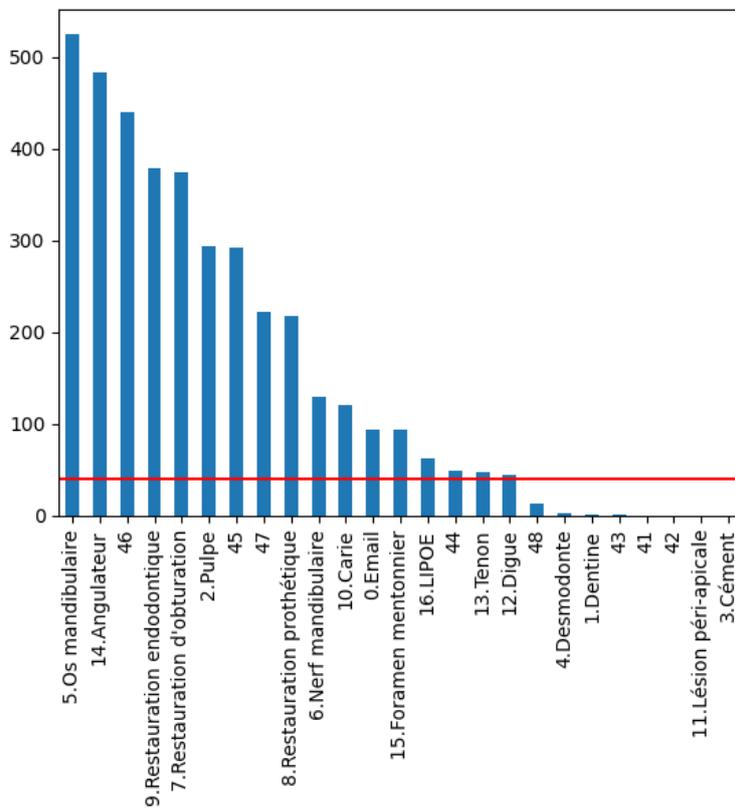


Figure 16 : Nombre d'images par classe

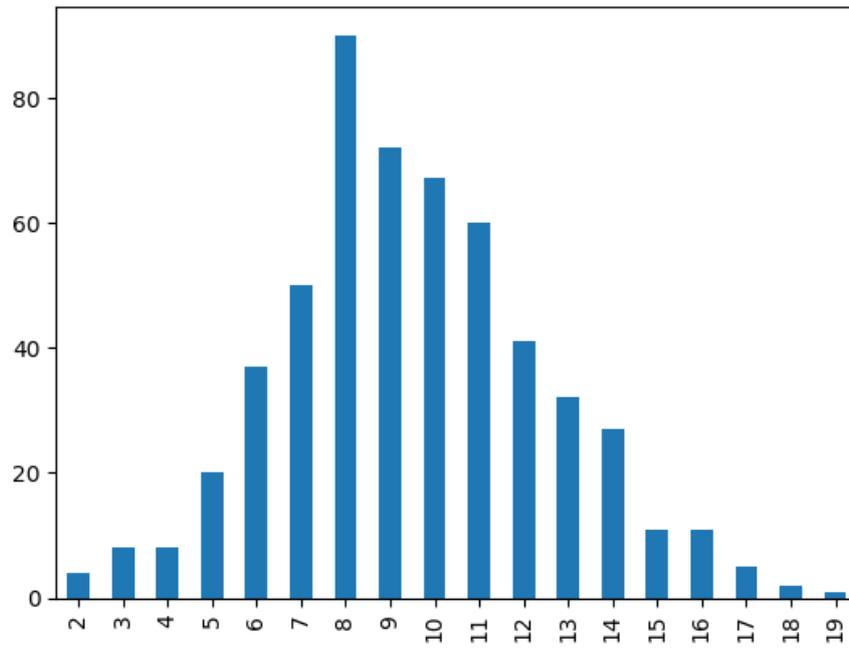


Figure 17 : Nombre d'annotations par image

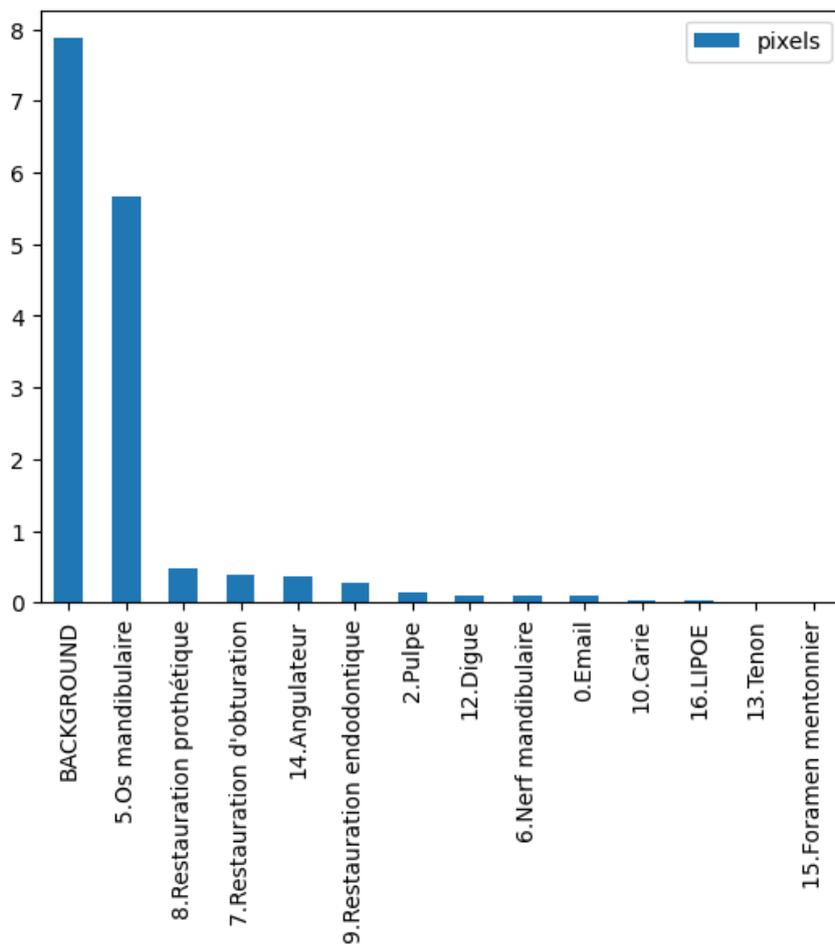


Figure 18 : Distribution des pixels par classe

La distribution des pixels par classe laisse apparaître un très grand déséquilibre. Les deux classes majoritaires occupant la quasi-totalité des images sont la classe "background" (pixels sans étiquette) et la classe "5. Os mandibulaire".

Il est donc important de tenir compte de ce déséquilibre, à la fois pour l'entraînement et pour l'évaluation des modèles de segmentation.

3.4.4. Exemple de segmentation

La segmentation consiste à délimiter les différentes classes, choisies au préalable, comme l'émail, les caries dentaires, l'angulateur ou encore les restaurations d'obturations.

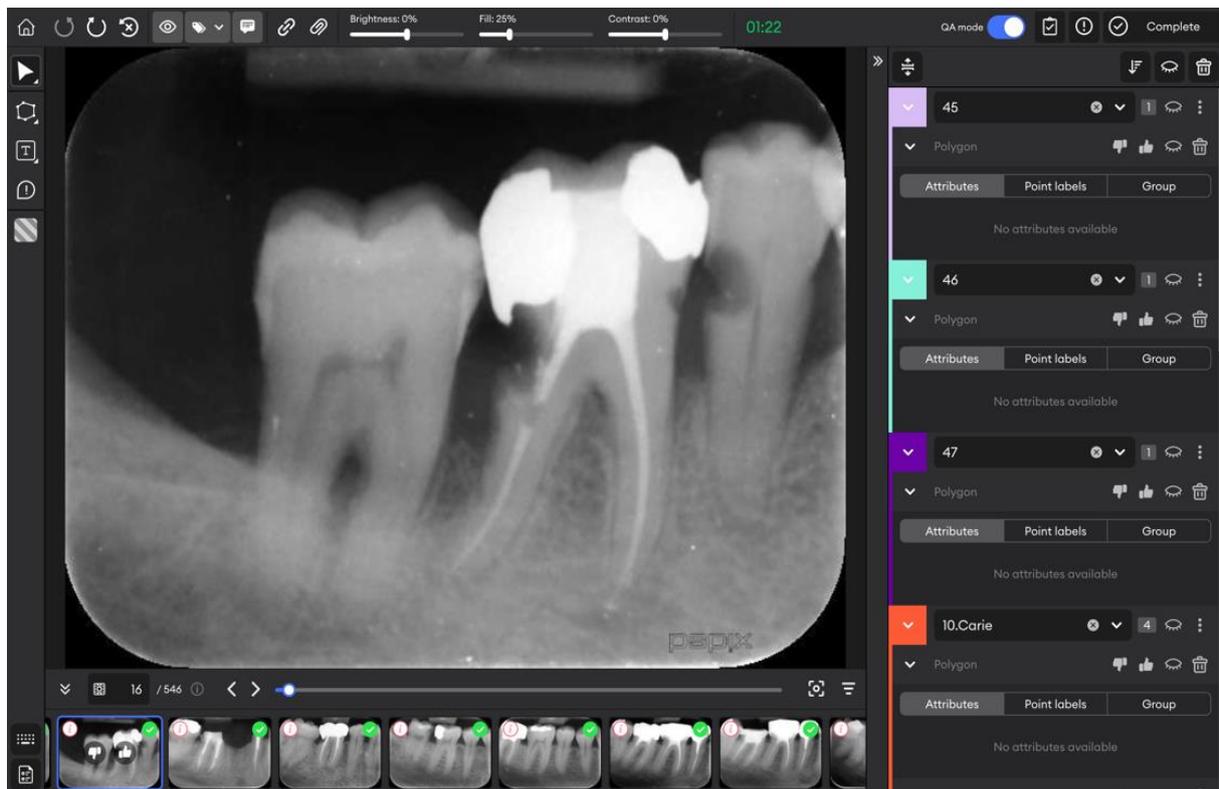


Figure 19 : Radiographie rétro-alvéolaire secteur 4 sur SuperAnnotate
(Source personnelle)



Figure 20 : Radiographie rétro-alvéolaire secteur 4 sur SuperAnnotate avec segmentation des classes (Source personnelle)

3.5. Création du modèle algorithmique

3.5.1. Schéma des étapes de création

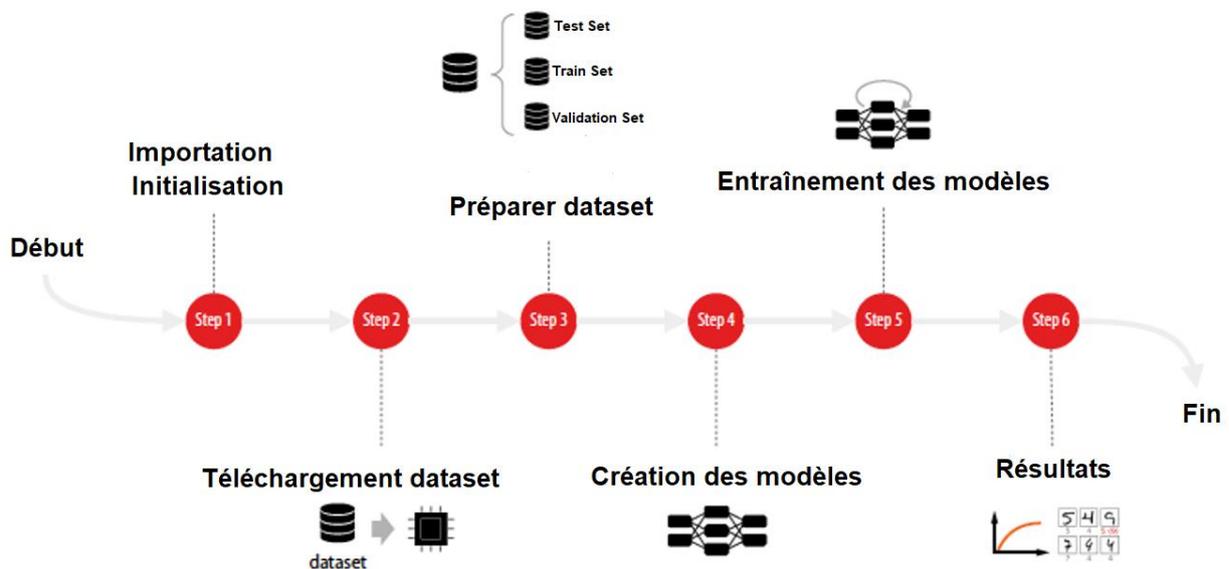


Figure 21 : Etapes pour la création du réseau de neurones profonds

De manière très simpliste, les différentes étapes dans la création du modèle algorithmique sont :

- Lancement et initialisation des différents logiciels comme *Tensorflow* et *Keras*
- Récupération des données
- Préparation des données
- Fabrication des modèles
- Apprentissage du modèle
- Analyse des résultats

3.5.2. Définitions et généralités

Le modèle algorithmique a été créé via l'utilisation conjointe de *TensorFlow* qui est un des outils open source d'apprentissage automatique développé par google ; et de *Keras* qui est une API ou *Advanced Programming Interface* de réseaux de neurones de haut niveau, écrite en Python et interfaçable avec *TensorFlow*.

Au vu des nombreux calculs nécessaires pour la programmation de ce réseau de neurones, il faut l'utilisation d'un GPU et non d'un CPU.

3.5.3. Préparation du jeu de données

Le jeu de données *ou dataset* sera divisé en trois parties distinctes pour des utilisations différentes.

- Une grande partie des données sera utilisée pour le groupe d'apprentissage/d'entraînement *ou trainset*.

C'est la partie des données utilisée pour construire le modèle d'apprentissage. Plusieurs choix de conception peuvent être possibles pendant la construction du modèle. Le réseau neuronal peut utiliser différents hyperparamètres pour le taux d'apprentissage ou la régularisation. Le même ensemble de données d'apprentissage peut être testé plusieurs fois avec différents choix d'hyperparamètres ou des algorithmes complètement différents pour construire les modèles de plusieurs manières. Ce processus permet d'estimer la précision relative des différents paramètres de l'algorithme. Ce processus prépare le terrain pour la sélection du modèle, dans lequel le meilleur algorithme est sélectionné parmi ces différents modèles. Cependant, l'évaluation réelle de ces algorithmes pour sélectionner le meilleur modèle n'est pas effectuée sur les données d'apprentissage, mais sur un ensemble de données de validation distinct afin d'éviter de favoriser les modèles surajoutés.

- Une plus petite partie des données sera utilisée pour le groupe de test *ou testset*.

C'est la partie des données utilisée pour tester la précision du modèle final (ajusté). Il est important que les données de test ne soient même pas consultées pendant le processus d'ajustement des paramètres et de sélection du modèle afin d'éviter tout surajustement. Les données de test ne sont utilisées qu'une seule fois, à la toute fin du processus. En outre, si l'analyste utilise les résultats des données de test pour ajuster le modèle d'une manière ou d'une autre, les résultats seront contaminés par les connaissances tirées des données de test. L'idée d'avoir autorisé à examiner un ensemble de données de test qu'une seule fois est une exigence extraordinairement

stricte (et importante). Pourtant, elle est souvent enfreinte dans les tests de référence réels. La tentation d'utiliser ce que l'on a appris lors de l'évaluation finale de la précision est tout simplement trop forte.

- Les données de validation **ou validation data**.

C'est la troisième partie des données utilisée pour la sélection du modèle et l'ajustement des paramètres. Par exemple, le choix du taux d'apprentissage peut être ajusté en construisant le modèle plusieurs fois sur la première partie de l'ensemble de données (c'est-à-dire les données d'apprentissage), puis en utilisant l'ensemble de validation pour estimer la précision de ces différents modèles. Différentes combinaisons de paramètres sont échantillonnées dans une fourchette et leur précision est testée sur l'ensemble de validation. Le meilleur choix de chaque combinaison de paramètres est déterminé en utilisant cette précision. Dans un sens, les données de validation doivent être considérées comme une sorte d'ensemble de données de test pour ajuster les paramètres de l'algorithme (par exemple, le taux d'apprentissage, le nombre de couches ou d'unités dans chaque couche), ou pour sélectionner le meilleur choix de conception (par exemple, activation sigmoïde contre activation tanh).

Notion de **validation croisée** :

- On divise l'ensemble de données en deux parties distinctes : un ensemble d'entraînement et un ensemble de test. L'ensemble de test est exclusivement réservé à l'évaluation du modèle et n'est pas utilisé pour son apprentissage.
- L'utilisation d'une fraction limitée des données pour l'apprentissage peut avoir un impact négatif sur la qualité de l'apprentissage, car moins de données signifient généralement un apprentissage moins efficace.
- Ainsi, la validation croisée va nous permettre d'utiliser l'intégralité de notre jeu de données pour l'entraînement et pour la validation.
- L'ensemble des données est divisé en k parties (**fold**s) approximativement égales. Successivement, chacune des k parties est utilisée comme jeu de test. Le reste (autrement dit, l'union des $k-1$ autres parties) est utilisé pour l'entraînement.
- À la fin, chaque point ou observation a été utilisé une fois dans un jeu de test, $(k-1)$ fois dans un jeu d'entraînement. Nous avons donc une prédiction par

point de mon jeu initial, et aucune de ces prédictions n'a été basée sur un jeu d'entraînement qui contenait ce point spécifique.

- Dans notre expérience, la validation croisée se fait sur 5 folds (entraînement sur 4 folds et validation sur le 5ème). Il n'y a aucune fuite de données (les évaluations sont faites sur des données non vues pendant l'entraînement).

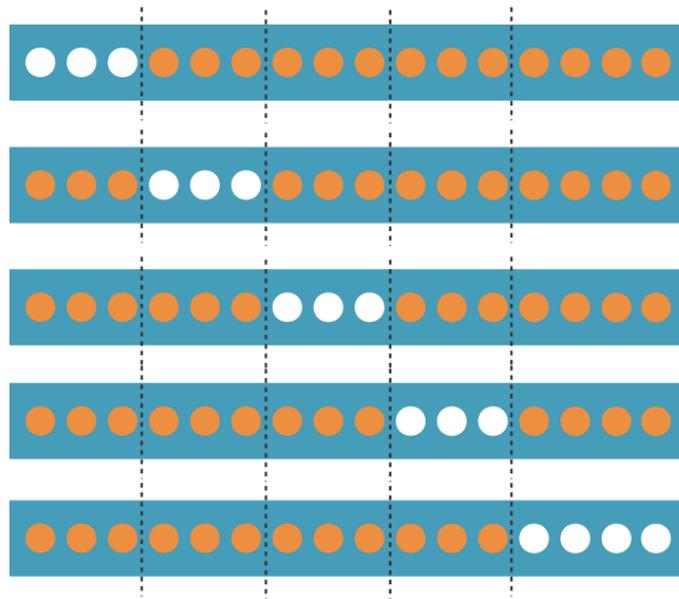


Figure 22 : Cross-validation à 5 folds : Chaque point appartient à 1 des 5 jeux de test (en blanc) et aux 4 autres jeux d'entraînements (en orange)

3.5.4. Les traitements opérés sur l'image

Elles sont de deux natures :

- Le **preprocessing** appliqué aux images que ce soit pour l'entraînement ou l'inférence. Un seul canal est utilisé car c'est les pixels sont en noir et blanc. Il faut en effet mettre ces images radiographiques au même et bon format avec :
 - Le redimensionnement ou *resizing* et le remplissage ou *padding* sont utilisés pour conserver l'échelle et les proportions.
 - Le *resizing* est utile pour redimensionner à une taille fixe et s'assurer que le modèle peut traiter toutes les entrées de manière cohérente. Cela fait référence au processus de modification de la taille d'une image tout en préservant son rapport hauteur/largeur. En outre, le redimensionnement d'une

image peut contribuer à réduire le coût de calcul du traitement de l'image en réduisant sa résolution.

- Le *padding* fait référence à la quantité de pixels ajoutés à une image lorsqu'elle est traitée par le noyau d'un CNN.
- Le *CLAHE* (contrast limited adaptive histogram equalization) : l'impact sur les performances sera évalué.

L'ensemble des données d'images annotées est prétraité pour améliorer la qualité de l'image et éliminer le bruit dans les images radiographiques.

Il a été constaté que CLAHE est plus performant que les autres techniques pour améliorer le contraste des images. Cette étude utilise CLAHE pour améliorer le contraste de l'image afin d'améliorer les performances du modèle léger de détection et de localisation des maladies proposées.

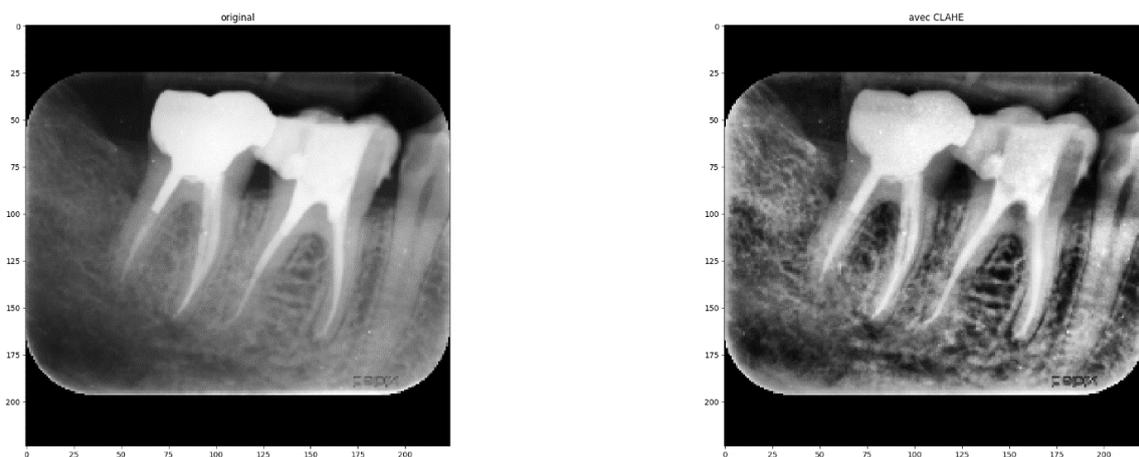


Figure 23 : Utilisation du CLAHE sur une radiographie rétro-alvéolaire

On visualise les différentes transformations et on s'assure que les *mask* sont correctement transformés (pour les transformations géométriques).

- **L'augmentation des données** : différentes transformations sont utilisées lors de l'entraînement pour prévenir le surapprentissage. Les transformations utilisées doivent également être appliquées si besoin aux annotations *ou mask*. Lors de l'entraînement ces transformations sont appliquées de façon aléatoire. On utilise : *crop + zoom*, rotation de moins de 5°, filtre gaussien/médian/moyen, variation de luminosité/contraste/gamma. On considère que le modèle n'est utilisable que dans une région centrée sur la

dent 46 ; c'est pourquoi on favorisera les *crop + zoom* le plus souvent centrés, on ne fera pas de flip horizontal et à plus forte raison pas de flip vertical.

L'augmentation des données ou *data augmentation* est une technique d'apprentissage automatique utilisée pour réduire l'ajustement excessif lors de la formation d'un modèle d'apprentissage automatique, en formant des modèles sur plusieurs copies légèrement modifiées de données existantes. C'est le processus permettant de générer des données d'entraînement supplémentaires. Elle consiste à appliquer des transformations sur des données existantes pour obtenir de nouvelles données.

La *data augmentation* se fait uniquement sur les données d'entraînement.

Pourquoi ? Elle est primordiale lorsque le jeu de données n'est pas assez conséquent. En effet, plus le jeu de données est important, plus l'entraînement du réseau de neurone sera important, plus les résultats seront bons.

Il est obligatoire de faire cette *data augmentation en contexte* afin de ne pas biaiser l'entraînement de l'algorithme et rester fidèle à notre objectif.

Ainsi, voici les choix de *data augmentations* retenus :

- Rotation de l'image radiographique de 5° maximum
- *Cropping* : Consiste à couper une zone. Une zone sur l'image radiographique est choisie aléatoirement et un zoom est fait dessus.
- Augmentation contraste et luminosité
- Filtre gaussien

Alors que d'autres choix non pas été retenus :

- Flip horizontal : Car cela changeait de côté la radiographie et la faisait passer pour un secteur 3.
- Flip vertical : Car cela changeait de côté la radiographie et la faisait passer pour un secteur 1.

On visualise les différentes transformations et on s'assure que les *mask* sont correctement transformés (pour les transformations géométriques).

Ci-dessous, voilà les exemples de *data augmentation* et leur impact sur les clichés radiographiques. L'image de gauche correspond à la radiographie rétro-alvéolaire originale. L'image du milieu correspond à l'application d'un type de *data augmentation*. L'image de droite correspond à la création des *mask* par l'algorithme.

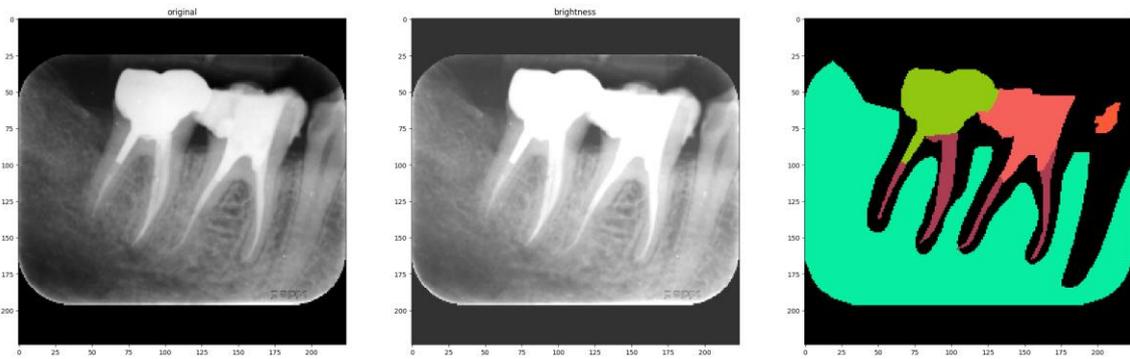


Figure 24 : Application d'un changement de luminosité comme Data Augmentation

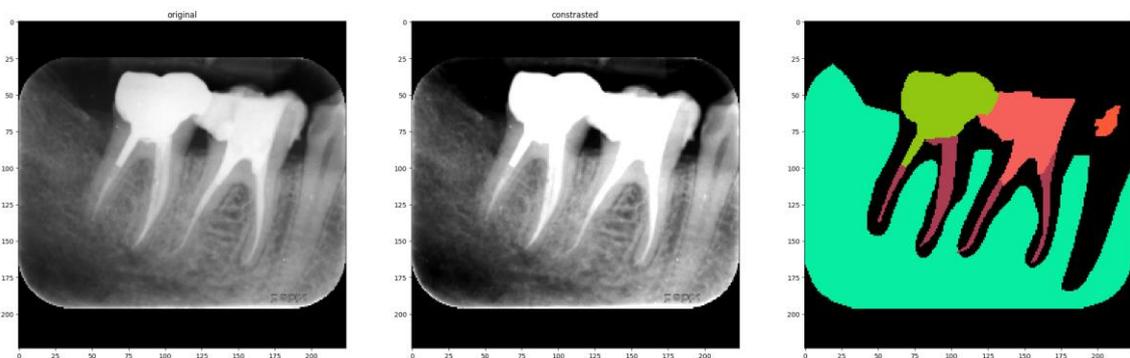


Figure 25 : Application d'un changement de contraste comme Data Augmentation

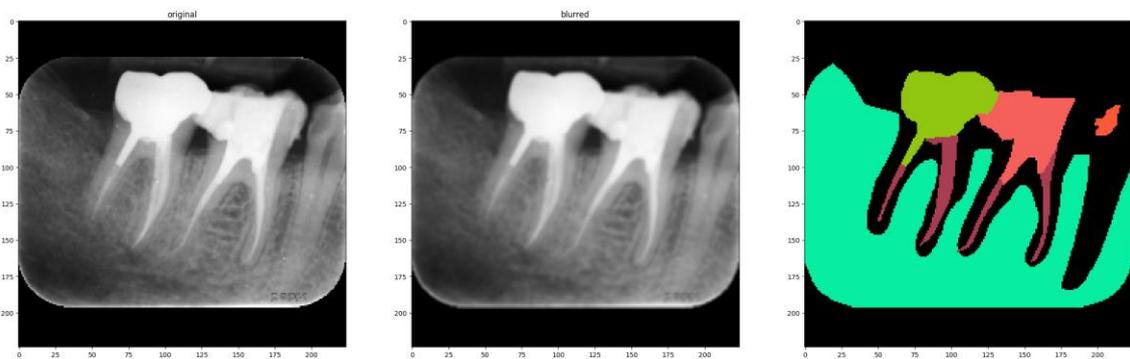


Figure 26 : Application d'un flou comme Data Augmentation

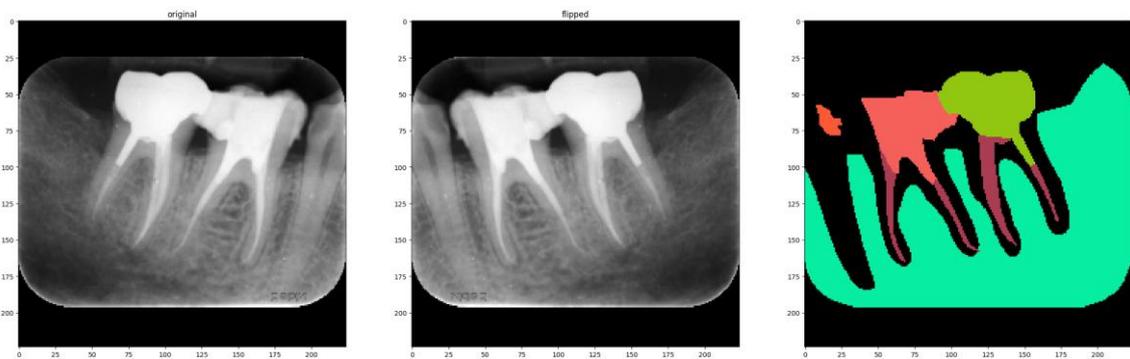


Figure 27 : Application d'un flip comme Data Augmentation

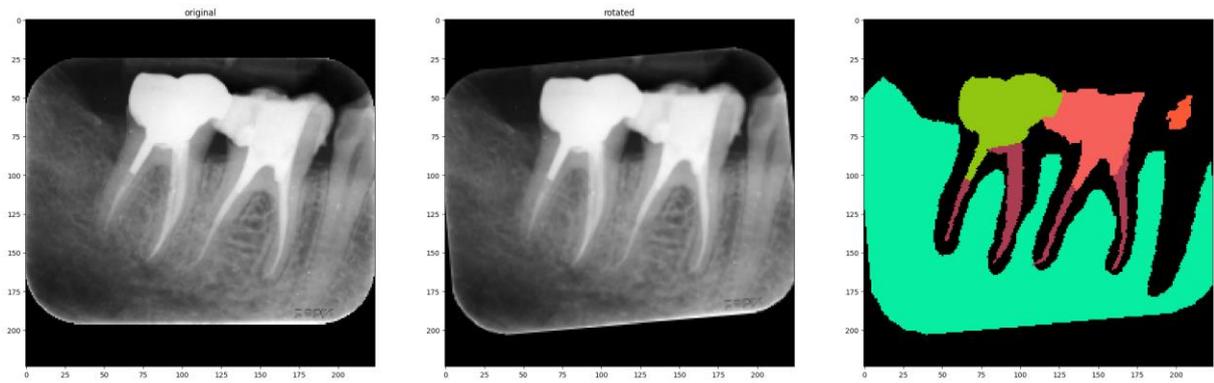


Figure 28 : Application d'une rotation comme Data Augmentation

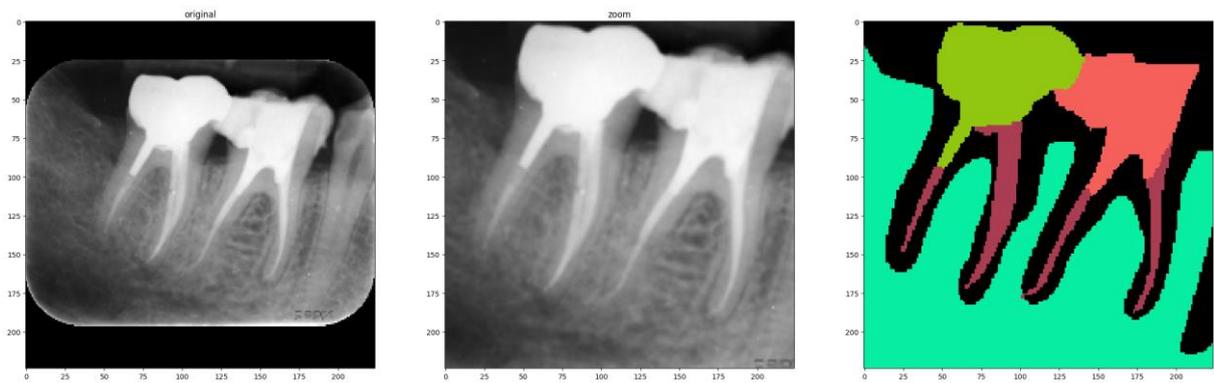


Figure 29 : Application d'un zoom comme Data Augmentation

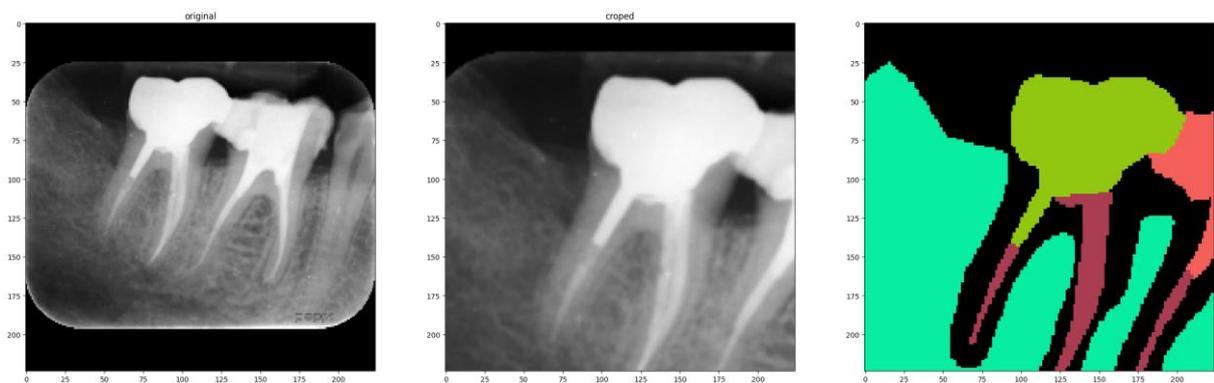


Figure 30 : Application du cropped comme Data Augmentation

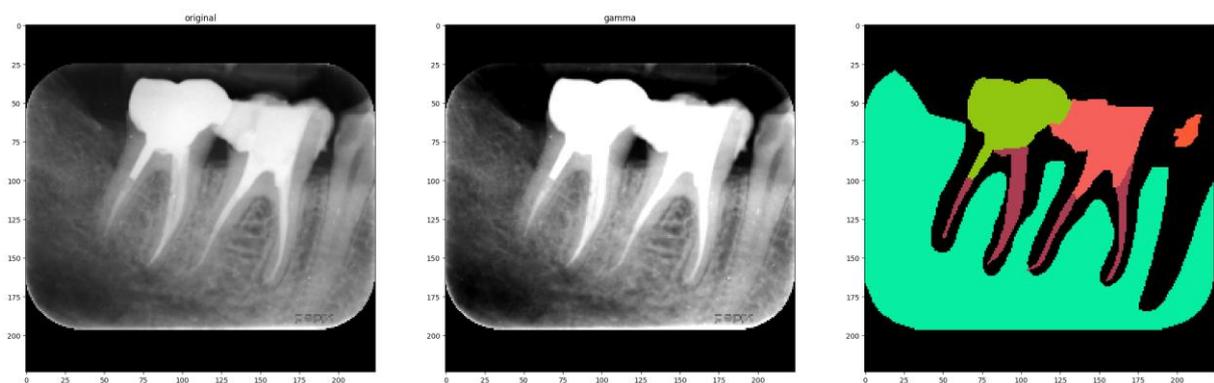


Figure 31 : Application d'un filtre gamma comme Data Augmentation

3.5.5. Test des différents modèles et paramètres par validation croisée

Les configurations testées sont décrites ci-dessous :

- model :
 - deeplabv3plus
 - xnet
- loss :
 - dl : dice loss
 - wfldl : somme de focal loss pondérée et de dice loss
 - wfl : focal loss pondérée
 - wcel : cross entropie pondérée
- backbone :
 - mobilenetv3small
 - vgg16
 - efficientnetb0
 - resnet50
 - resnet50v2
- transfer learning :
 - fromscratch : le backbone est entraîné complètement (50 epochs)
 - frozen : les poids du backbone sont gelés (30 epochs)
 - finetuning : les poids du bacbone sont gelés (10 epochs) puis dégelés (20 epochs) ; le dégel partiel n'est pas testé
- augmentation :
 - aug
 - noaug
- preprocessing :
 - orig
 - clahe
- image_size
 - 224
 - 448
 - 512

Figure 32 : Imprim écran des configurations testées

En effet, on teste différents paramètres et différentes configurations puis on garde la composition qui donne les meilleurs résultats.

Model : Les architectures de segmentation sémantique utilisées ici sont *Unet*, *Unet++* (noté *xnet*) et *Deeplabv3+*.

Pour *Unet++* (*xnet*) et *Deeplabv3+*, on utilise des couches de réseau existant, qu'on réentraîne ou pas.

Notion d'encodeur et de décodeur :

De manière très simplifiée nous avons deux parties : une première qui extrait des "features" qui donne une représentation latente de l'image et ensuite une deuxième partie qui reconstitue une image (très simplifiée), le *mask*.

A savoir que les encodeurs sont souvent prés entraînés.

Nous avons testé différents encodeurs : pour *unet++* : *officialnet* et pour *deeplabv3+* : *mobynt*.

Loss : La **fonction de perte** ou *loss function*, est une fonction qui évalue l'écart entre les prédictions réalisées par le réseau de neurones et les valeurs réelles des observations utilisées pendant l'apprentissage. Plus le résultat de cette fonction est minimisé, en réajustant les poids, plus le réseau de neurones est performant. Cette fonction de perte se fait au moment du test.

La descente de gradient a pour but de minimiser la fonction de perte en ajustant petit à petit les paramètres d'apprentissage représentés par les différents poids.

Ici, il a été testé 4 *loss* différentes que sont *dl*, *wfdl*, *wfl* et *wcel*.

Transfer learning : L'**apprentissage par transfert** ou *transferlearning*, désigne l'ensemble des méthodes qui permettent de transférer les connaissances acquises à partir de la résolution de problèmes donnés pour traiter un autre problème.

Ici, il a été testé 3 types que sont *fromscratch*, *frozen* et *finetuning*.

Les résultats sont synthétisés dans une table :

| | name | mean_iou | io_u_8 | epochs | model | loss | backbone | transfer learning | data augmentation | preprocessing | image size |
|----|---|----------|----------|--------|---------------|-------|------------------|-------------------|-------------------|---------------|------------|
| 8 | xnet-wfddl-resnet50-fromscratch-aug-orig-448 | 0.486249 | 0.433243 | 47 | xnet | wfddl | resnet50 | fromscratch | aug | orig | 448 |
| 10 | xnet-wfddl-resnet50-fromscratch-aug-orig-512 | 0.483311 | 0.387393 | 40 | xnet | wfddl | resnet50 | fromscratch | aug | orig | 512 |
| 24 | xnet-wfddl-resnet50-frozen-aug-orig-224 | 0.478919 | 0.320917 | 22 | xnet | wfddl | resnet50 | frozen | aug | orig | 224 |
| 19 | deeplabv3plus-wfddl-resnet50-fromscratch-aug-o... | 0.478228 | 0.346578 | 40 | deeplabv3plus | wfddl | resnet50 | fromscratch | aug | orig | 448 |
| 20 | deeplabv3plus-wfddl-resnet50-fromscratch-aug-c... | 0.473483 | 0.358645 | 44 | deeplabv3plus | wfddl | resnet50 | fromscratch | aug | clahe | 512 |
| 0 | xnet-wfddl-resnet50-fromscratch-aug-orig-224 | 0.471782 | 0.277145 | 43 | xnet | wfddl | resnet50 | fromscratch | aug | orig | 224 |
| 26 | xnet-wfddl-resnet50-fromscratch-aug-clahe-448 | 0.471725 | 0.326377 | 37 | xnet | wfddl | resnet50 | fromscratch | aug | clahe | 448 |
| 17 | deeplabv3plus-wfddl-resnet50-fromscratch-aug-o... | 0.469972 | 0.267215 | 48 | deeplabv3plus | wfddl | resnet50 | fromscratch | aug | orig | 224 |
| 14 | xnet-wfddl-resnet50-frozen-aug-clahe-448 | 0.468833 | 0.302708 | 27 | xnet | wfddl | resnet50 | frozen | aug | clahe | 448 |
| 2 | xnet-wfddl-resnet50-finetuning-aug-orig-224 | 0.468601 | 0.313256 | 6 | xnet | wfddl | resnet50 | finetuning | aug | orig | 224 |
| 1 | xnet-wfddl-resnet50-fromscratch-noaug-orig-224 | 0.467285 | 0.305834 | 28 | xnet | wfddl | resnet50 | fromscratch | noaug | orig | 224 |
| 15 | xnet-wfddl-resnet50-fromscratch-aug-clahe-224 | 0.464974 | 0.249002 | 30 | xnet | wfddl | resnet50 | fromscratch | aug | clahe | 224 |
| 5 | xnet-wfddl-resnet50-frozen-aug-clahe-224 | 0.460568 | 0.338286 | 29 | xnet | wfddl | resnet50 | frozen | aug | clahe | 224 |
| 25 | deeplabv3plus-wfddl-resnet50-fromscratch-aug-c... | 0.459393 | 0.304726 | 42 | deeplabv3plus | wfddl | resnet50 | fromscratch | aug | clahe | 224 |
| 22 | xnet-wfddl-efficientnetb0-frozen-aug-clahe-224 | 0.458057 | 0.277584 | 28 | xnet | wfddl | efficientnetb0 | frozen | aug | clahe | 224 |
| 6 | xnet-wfddl-resnet50v2-frozen-aug-clahe-224 | 0.454672 | 0.302931 | 21 | xnet | wfddl | resnet50v2 | frozen | aug | clahe | 224 |
| 27 | xnet-dl-resnet50-frozen-aug-orig-224 | 0.453313 | 0.295238 | 26 | xnet | dl | resnet50 | frozen | aug | orig | 224 |
| 18 | xnet-wfddl-mobilenetv3small-fromscratch-aug-or... | 0.446465 | 0.271689 | 45 | xnet | wfddl | mobilenetv3small | fromscratch | aug | orig | 224 |
| 4 | xnet-wfddl-mobilenetv3small-finetuning-aug-or... | 0.444330 | 0.296818 | 10 | xnet | wfddl | mobilenetv3small | finetuning | aug | orig | 224 |
| 23 | xnet-wfddl-mobilenetv3small-frozen-aug-clahe-224 | 0.425441 | 0.261269 | 22 | xnet | wfddl | mobilenetv3small | frozen | aug | clahe | 224 |
| 21 | deeplabv3plus-wfddl-mobilenetv3small-fromscrat... | 0.418253 | 0.259617 | 45 | deeplabv3plus | wfddl | mobilenetv3small | fromscratch | aug | clahe | 224 |
| 28 | deeplabv3plus-wfddl-vgg16-frozen-aug-clahe-224 | 0.403451 | 0.166450 | 28 | deeplabv3plus | wfddl | vgg16 | frozen | aug | clahe | 224 |
| 12 | deeplabv3plus-wfddl-resnet50v2-frozen-aug-clah... | 0.400998 | 0.202295 | 18 | deeplabv3plus | wfddl | resnet50v2 | frozen | aug | clahe | 224 |
| 3 | deeplabv3plus-wfddl-efficientnetb0-frozen-aug-... | 0.400631 | 0.195326 | 23 | deeplabv3plus | wfddl | efficientnetb0 | frozen | aug | clahe | 224 |
| 9 | deeplabv3plus-wfddl-resnet50-frozen-aug-clahe-224 | 0.395925 | 0.188330 | 25 | deeplabv3plus | wfddl | resnet50 | frozen | aug | clahe | 224 |
| 7 | unet-wfddl---aug-orig-224 | 0.388118 | 0.214511 | 46 | unet | wfddl | | | aug | orig | 224 |
| 29 | deeplabv3plus-wfddl-mobilenetv3small-frozen-au... | 0.388027 | 0.148325 | 28 | deeplabv3plus | wfddl | mobilenetv3small | frozen | aug | clahe | 224 |
| 16 | xnet-wfddl-vgg16-frozen-aug-clahe-224 | 0.372014 | 0.143026 | 17 | xnet | wfddl | vgg16 | frozen | aug | clahe | 224 |
| 13 | xnet-wcel-resnet50-frozen-aug-orig-224 | 0.356780 | 0.174479 | 29 | xnet | wcel | resnet50 | frozen | aug | orig | 224 |
| 11 | xnet-wfl-resnet50-frozen-aug-orig-224 | 0.356099 | 0.178297 | 23 | xnet | wfl | resnet50 | frozen | aug | orig | 224 |

Figure 33 : Imprim écran des résultats synthétisés dans une table

Ainsi la composition retenue avec le meilleur résultat (iou_max à 0.49) est :

Modèle : xnet

Loss : wfddl

Backbone : resnet50

Transfer learning : fromscratch

Augmentation : aug

Taille image : 448

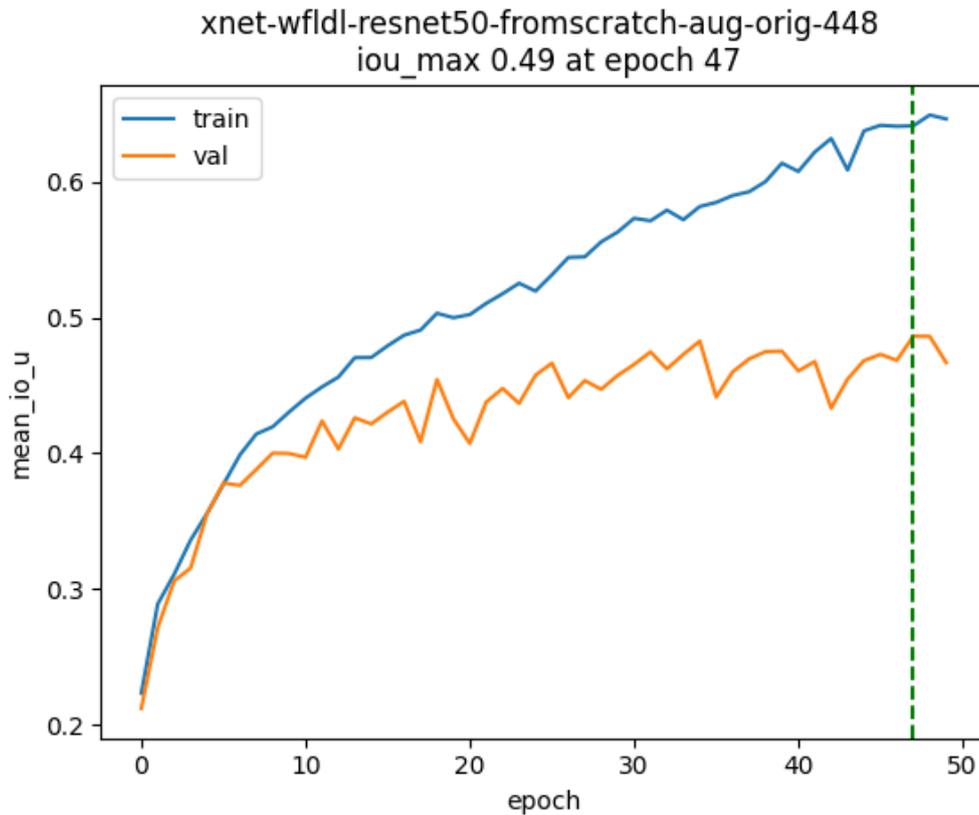


Figure 34 : Résultat optimal de l'IoU moyen

On observe rapidement le phénomène de surapprentissage à moins de dix itérations avec un plateau pour la validation.

Le surapprentissage ou *overfitting* est un phénomène qui se produit lors de l'entraînement d'un modèle d'apprentissage automatique. Cela arrive lorsque le modèle est trop complexe ou lorsqu'il est entraîné avec trop peu de données, ce qui entraîne une mauvaise généralisation.

Lorsque le surapprentissage se produit, le modèle apprend à "trop bien" s'adapter aux données d'entraînement spécifiques sur lesquelles il a été formé, mais il ne parvient pas à généraliser correctement pour des données inconnues. En conséquence, le modèle peut devenir très précis pour les données d'entraînement, mais il ne sera pas capable de prédire avec précision de nouvelles données.

Les signes courants de surapprentissage comprennent une erreur d'entraînement très faible, mais une erreur de validation ou de test élevée. Le modèle peut également commencer à mémoriser les exemples individuels plutôt que d'apprendre des caractéristiques générales et discriminantes. On l'observe dans la validation avant les résultats.

3.6. Résultats

3.6.1. Métriques retenues et définitions

Nous avons décidé de retenir les métriques suivantes :

La **Valeur prédictive positive** (=VPP) ou *precision en anglais* : désigne la probabilité lorsqu'un test est positif qu'une condition soit présente.

$$Precision = \frac{\text{Vrai Positif}}{\text{Vrai Positif} + \text{Faux Positif}}$$

La **sensibilité** ou *recall en anglais* : d'un test mesure sa capacité à donner un résultat positif lorsqu'une hypothèse est vérifiée.

$$Recall = \frac{\text{Vrai Positif}}{\text{Vrai Positif} + \text{Faux Négatif}}$$

Coefficient de Dice : est un indicateur statistique qui mesure la similarité de deux échantillons.

Il est également appelé Score F1 qui est une moyenne harmonique.

Coefficient de Jaccard : est un indicateur utilisé statistique qui compare la similarité et la diversité entre des échantillons.

Il est également appelé IoU ou *Intersection over Union* et correspond donc à l'étendue de l'intersection entre le rectangle d'encadrement prédit et le rectangle d'encadrement cible, divisée par l'étendue de leur union. Il traduit donc la qualité de la superposition.

$$IoU = |A \cap B| \div |A \cup B| = |I| \div |U|$$

I = Intersection area

U = Union area

D'après l'équation ci-dessus, A et B sont les boîtes de délimitation cible et de prédiction, comme illustré ci-dessous :

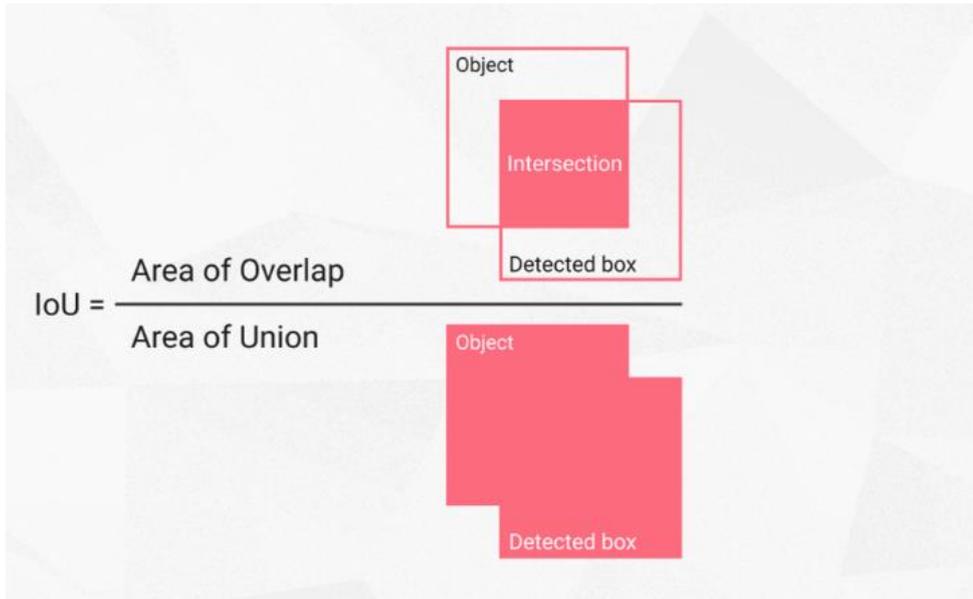


Figure 35 : Equation du calcul de l'IoU

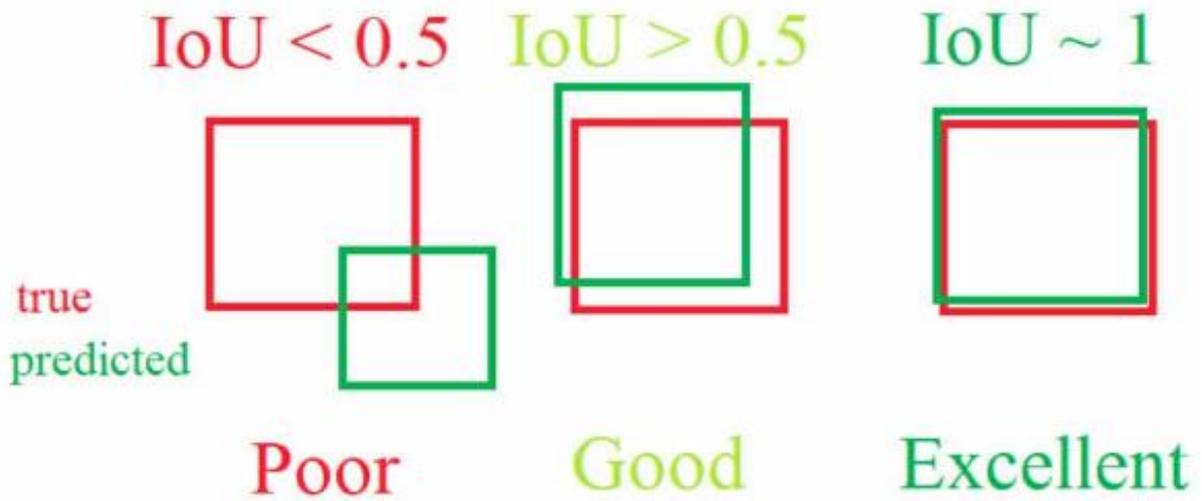


Figure 36 : Schéma synthétique d'un IoU faible, bon et excellent

3.6.2. Résultats tableaux

| | Precision-PVW | Recall-Sensitivity | Specificity | NPV | F1 | IoU | mask | name |
|------|---------------|--------------------|-------------|----------|----------|----------|------|-----------------------------|
| 0 | 0.945577 | 0.945059 | 0.916261 | 0.915489 | 0.945318 | 0.896306 | 0.0 | BACKGROUND |
| 1 | 0.458114 | 0.297392 | 0.998250 | 0.996511 | 0.360657 | 0.220001 | 1.0 | 0.Email |
| 2 | 0.584757 | 0.480822 | 0.996655 | 0.994922 | 0.527721 | 0.358438 | 2.0 | 2.Pulpe |
| 3 | 0.914282 | 0.930295 | 0.964501 | 0.971426 | 0.922219 | 0.855664 | 3.0 | 5.Os mandibulaire |
| 4 | 0.247921 | 0.278408 | 0.995214 | 0.995908 | 0.262282 | 0.150935 | 4.0 | 6.Nerf mandibulaire |
| 5 | 0.740533 | 0.778441 | 0.994413 | 0.995457 | 0.759014 | 0.611622 | 5.0 | 7.Restauration d'obturation |
| 6 | 0.815624 | 0.726435 | 0.996708 | 0.994528 | 0.768450 | 0.623970 | 6.0 | 8.Restauration prothétique |
| 7 | 0.842052 | 0.787794 | 0.997975 | 0.997095 | 0.814020 | 0.686369 | 7.0 | 9.Restauration endodontique |
| 8 | 0.629382 | 0.479894 | 0.999410 | 0.998915 | 0.544565 | 0.374160 | 8.0 | 10.Carie |
| 9 | 0.917204 | 0.866109 | 0.999467 | 0.999088 | 0.890924 | 0.803303 | 9.0 | 12.Digue |
| 10 | 0.662415 | 0.502880 | 0.999832 | 0.999674 | 0.571727 | 0.400292 | 10.0 | 13.Tenon |
| 11 | 0.891536 | 0.907315 | 0.997814 | 0.998164 | 0.899356 | 0.817118 | 11.0 | 14.Angulateur |
| 12 | 0.096119 | 0.118697 | 0.999534 | 0.999632 | 0.106222 | 0.056090 | 12.0 | 15.Foramen mentonnier |
| 13 | 0.455766 | 0.627647 | 0.998777 | 0.999392 | 0.528072 | 0.358762 | 13.0 | 16.LIPOE |
| mean | 0.657234 | 0.623371 | 0.989629 | 0.989729 | 0.635753 | 0.515217 | NaN | NaN |

Figure 37 : Résultats du réseau de neurones des différentes classes évaluées

Precision = Valeur prédictive positive

Recall = Sensibilité

Specificity = Spécificité

NPV = *Negative Predictive Value* = Valeur prédictive négative

Le score F1 = Moyenne harmonique de la précision et du rappel = Coefficient de DICE

IoU = Intersection over Union = Score de Jaccard

Mask : Numéro par ordre des mask

Name : Nom de la classe

Toutes ces métriques sont calculées par classe (et non par image) à l'échelle du pixel sur l'ensemble du test set. Plusieurs résultats sont intéressants ici à commenter :

1^{ère} observation : Les résultats portant sur les 2 classes pathologiques (**10. Carie et 16. LIPOE**) sont perfectibles. Cela peut s'expliquer par leur relative rareté dans notre jeu de données. Deux phénomènes peuvent expliquer cela. Premièrement, leur présence sur une radiographie rétro-alvéolaire n'est pas majoritaire. Deuxièmement, leur segmentation n'a pas toujours été faite par oubli car sans contexte clinique il n'est pas toujours évident de l'objectiver.

On peut ainsi noter pour la carie une sensibilité de 48%, une VPP de 63%, un IoU de 37% et un score F1 de 54%. Pour la LIPOE, la sensibilité est de 63%, la VPP de 46%, un IoU de 36% et un score F1 de 53%.

D'un point de vue plus positif, la spécificité et la VPN de la carie et de la LIPOE, sont à 99%.

2^{ème} observation : Les classes plus représentées en volume présentent de meilleurs résultats. Par exemple, **5. l'os mandibulaire** présente de bons résultats avec une sensibilité de 93%, une VPP de 91%, un IoU de 86% et un score F1 de 92%.

Cela s'explique donc par sa présence dans toutes les radiographies rétro-alvéolaires et par sa nature qui paraît facilement reconnaissable pour le réseau de neurones.

3.6.3. Résultats par l'image du RNA

On visualise les prédictions sur un échantillon d'images de l'ensemble test.

Sur les différents exemples qui suivent, l'image de gauche correspond à la radiographie rétro-alvéolaire de base. L'image du milieu correspond à la segmentation juste effectuée par le dentiste. Enfin, l'image de droite correspond à la prédiction faite par le réseau de neurones.

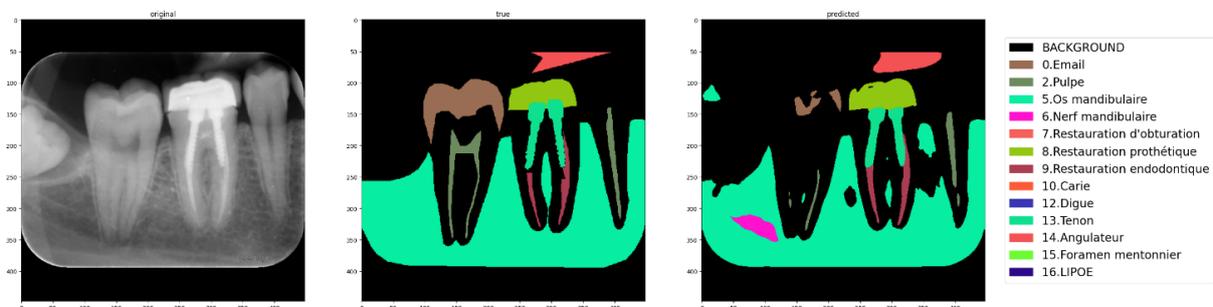


Figure 38 : Exemple 1 de prédiction donnée par le RNA

Exemple 1 : Cas parfait avec la segmentation faite et *mask* repéré total.

Concentrons-nous sur 46. Ici, nous avons segmenté différentes classes (image du milieu) : 8. Restauration prothétique, 13. *Tenon* et 9. *Restauration endodontique*.

L'algorithme a réussi à prédire ces 3 classes là (sur l'image de droite) avec en plus une intégrité quasi parfaite. En effet, les 3 *mask* sont identiques entre les 2 images.

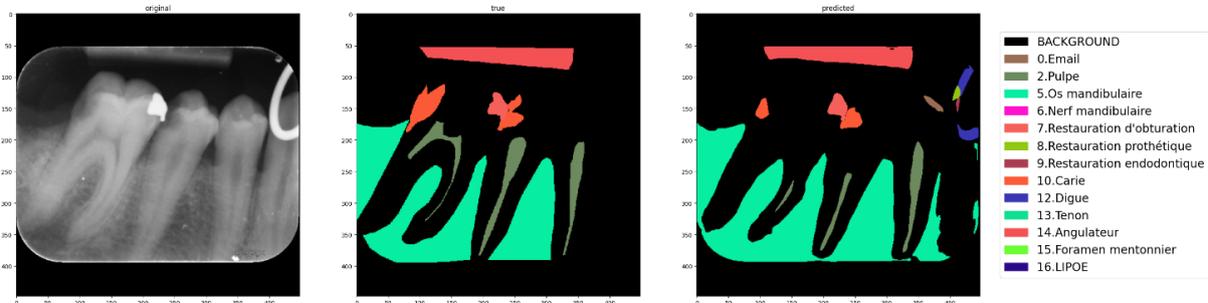


Figure 39 : Exemple 2 de prédiction donnée par le RNA

Exemple 2 : Cas concluant avec la segmentation faite et *mask* repéré mais partiel.

Concentrons-nous sur 46. Ici, nous avons segmenté différentes classes : 10. *Carie* sur 46 distal, la 2. *Pulpe* et une 7. *Restauration d'obturation* sur 46 mésial.

L'algorithme a réussi à prédire ces 3 classes là mais l'intégrité n'est pas parfaite. En effet, la carie est prédite plus petite que celle visible sur la radiographie et la pulpe n'est prédite qu'en toute petite partie dans l'une des racines mésiales. La restauration d'obturation en mésiale est quant à elle entièrement prédite. On aura donc ici une sensibilité et une VPP validés et un IoU positif mais faible.

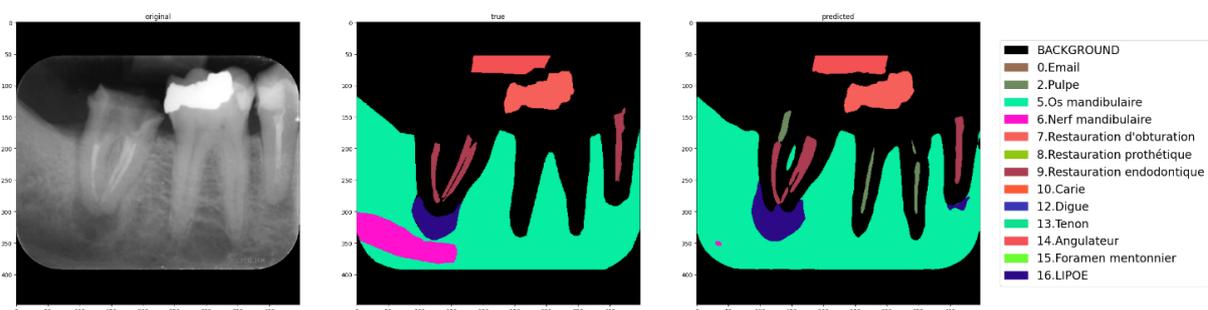


Figure 40 : Exemple 3 de prédiction donnée par le RNA

Exemple 3 : Cas non concluant avec la segmentation **non** faite mais *mask* de la projection juste.

Concentrons-nous sur 45 et 46. Ici, nous n'avons **pas** segmenté la 2. *Pulpe* de 46. Et nous n'avons pas non plus segmenté la 16. *LIPOE* de 45. Ces classes sont pourtant bel et bien présentes. Or, l'algorithme les a bien détectées comme on peut le voir sur l'image de droite. Ce cas montre bien que l'algorithme fonctionne mais les statistiques en seront biaisées.

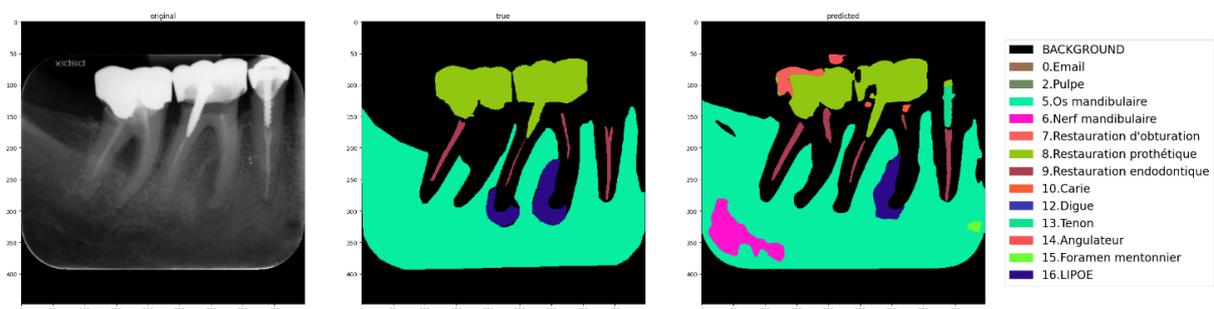


Figure 41 : Exemple 4 de prédiction donnée par le RNA

Exemple 4 : Cas non concluant avec la segmentation faite mais *mask* absent.

Concentrons-nous sur 46. Ici, nous avons segmenté plusieurs classes dont des 16. *LIPOE* sur les racines mésiales et distales de 46. Sur la projection de l'algorithme, la LIPOE sur les racines mésiales sont présentes mais celle sur la racine distale est absente.

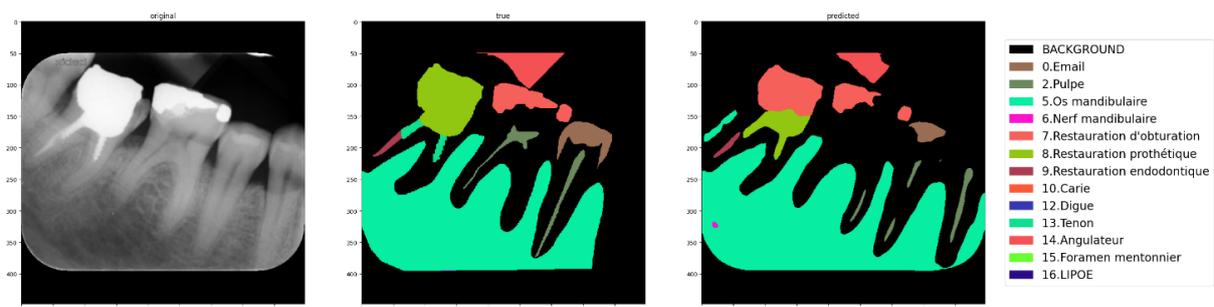


Figure 42 : Exemple 5 de prédiction donnée par le RNA

Exemple 5 : Cas non concluant avec la segmentation faite mais *mask* prédit différent. (Cf. matrice de confusion)

Concentrons-nous sur 47. Ici, nous avons segmenté une 8. *Restauration prothétique* et ses 13. *Tenon*. L'image projeté du RNA ne nous met pas les tenons existants et surtout nous donne comme partie supérieure de la restauration prothétique de la 7.

Restauration d'obturation qui n'est pas vraie ici. Il y a donc ici une confusion partielle de la restauration prothétique par de la restauration d'obturation.

Rappelons-nous, 30 radiographies rétro-alvéolaire de notre pool initial de 576 radiographies n'ont pas été segmentées.

Nous avons donc testé l'algorithme entraîné sur ces clichés vierges de toute segmentation.

Nous avons sur les prochains exemples, à gauche le cliché rétro-alvéolaire d'origine, au milieu la prédiction du modèle algorithmique et à droite la superposition des *mask* créés sur la radiographie d'origine.

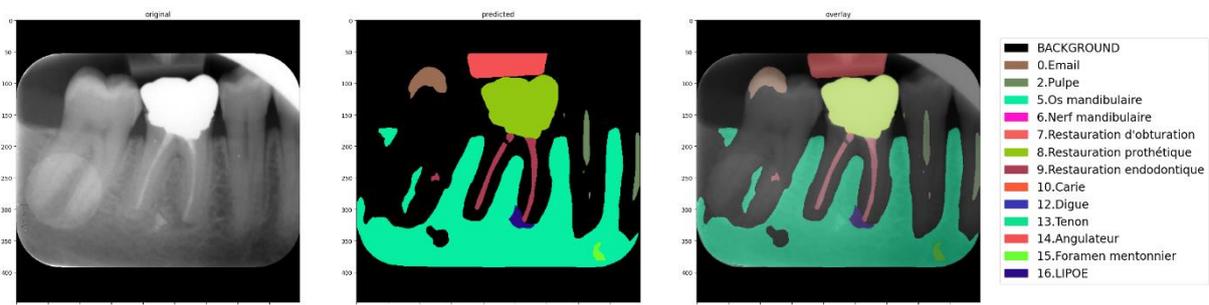


Figure 43 : Exemple 1 sur radiographie vierge de toute segmentation

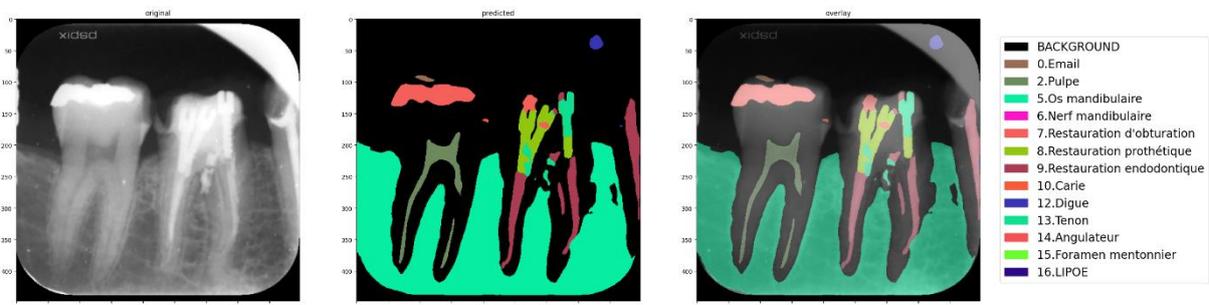


Figure 44 : Exemple 2 sur radiographie vierge de toute segmentation

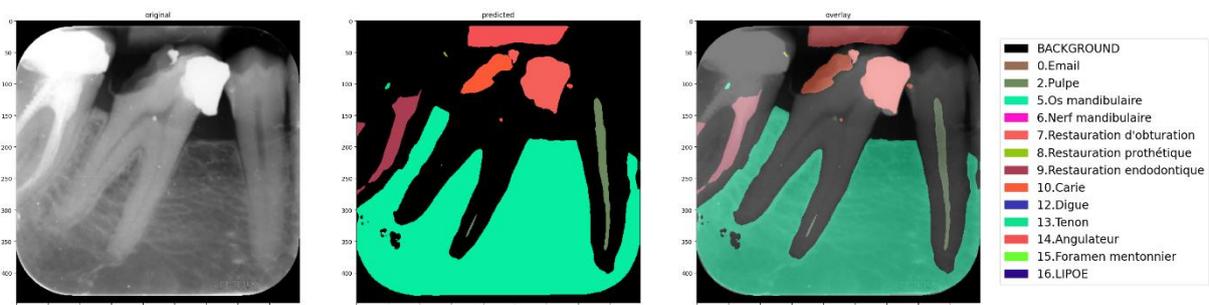


Figure 45 : Exemple 3 sur radiographie vierge de toute segmentation

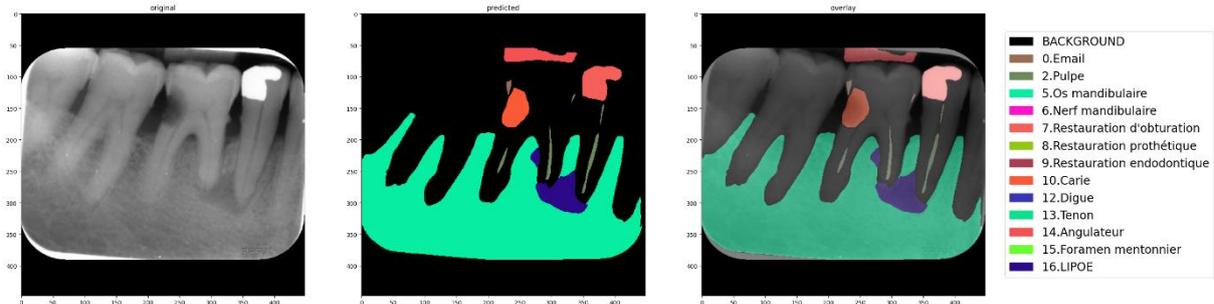


Figure 46 : Exemple 4 sur radiographie vierge de toute segmentation

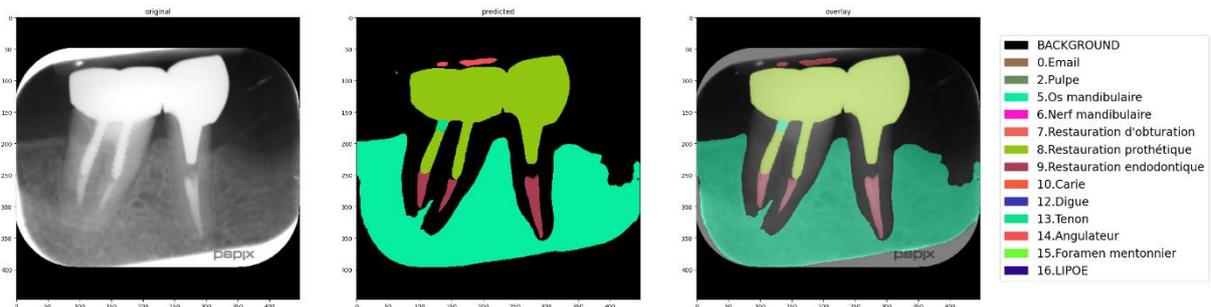


Figure 47 : Exemple 5 sur radiographie vierge de toute segmentation

3.6.4. Matrice de confusion

Définition : La matrice de confusion est un outil de mesure de la performance d'un système de classification. Chaque ligne de la matrice représente une classe réelle, tandis que chaque colonne représente une classe prédite. La cellule ligne L, colonne C contient le nombre d'éléments de la classe réelle L qui ont été estimés comme appartenant à la classe C.

La matrice de confusion permet de comprendre les erreurs de classification.

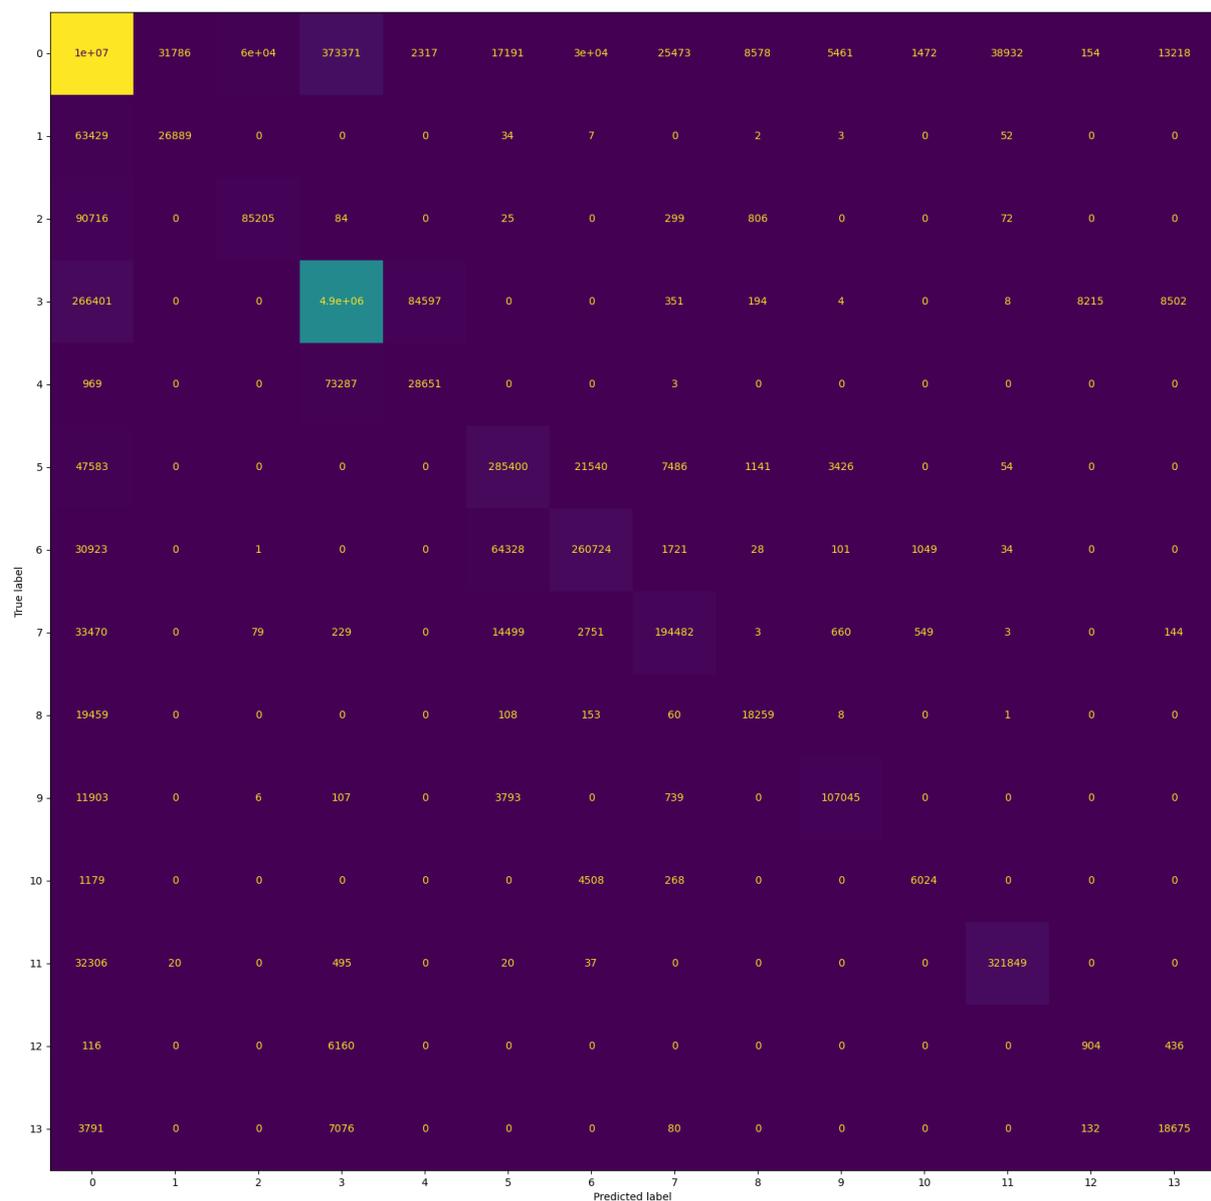


Figure 48 : Matrice de confusion (nombre de pixels)

Les labels prédits se lisent en abscisse alors que les vrais labels se lisent en ordonnée.

Les chiffres sur les deux axes correspondent aux numéros de classes que nous avons donnés. Le chiffre 8 correspond à la carie et le chiffre 0 à l'arrière-plan (*background*).

Ainsi ici, 8578 pixels ont été prédits comme carie alors qu'il s'agissait du *background*.

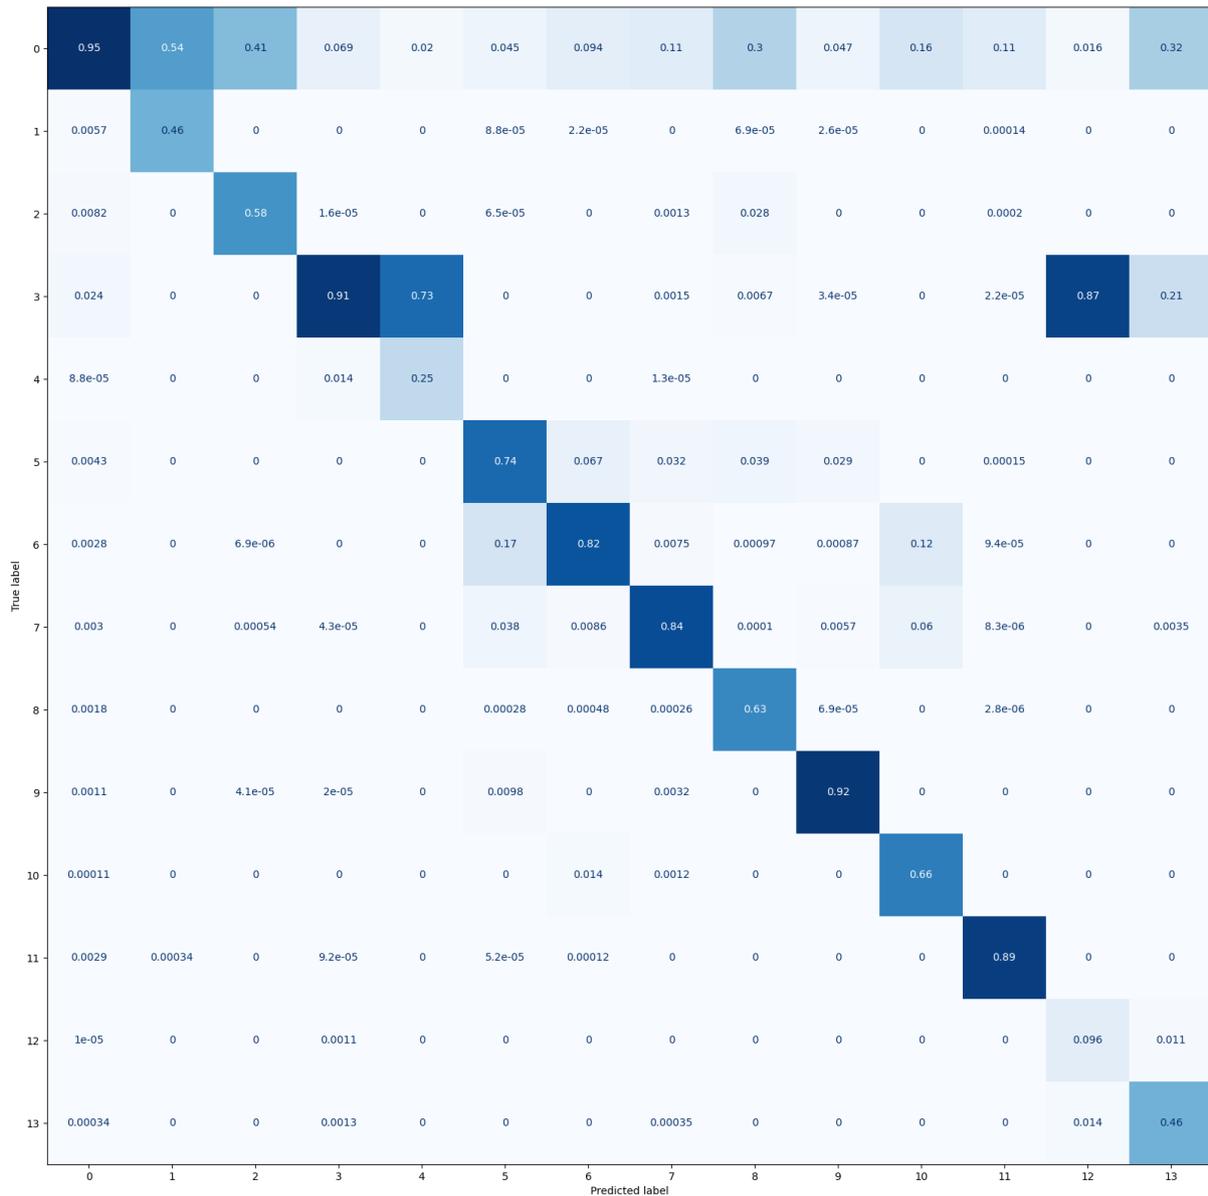


Figure 49 : Matrice de confusion
(pourcentage de pixels par classe prédite)

Les labels prédits se lisent en abscisse alors que les vrais labels se lisent en ordonnée.

Les chiffres sur les deux axes correspondent aux numéros de classes que nous avons donnés. Le chiffre 8 correspond à la carie et le chiffre 0 à l'arrière-plan.

Ainsi ici, 30% des pixels de carie ont été prédits comme carie alors qu'il s'agissait du *background*.

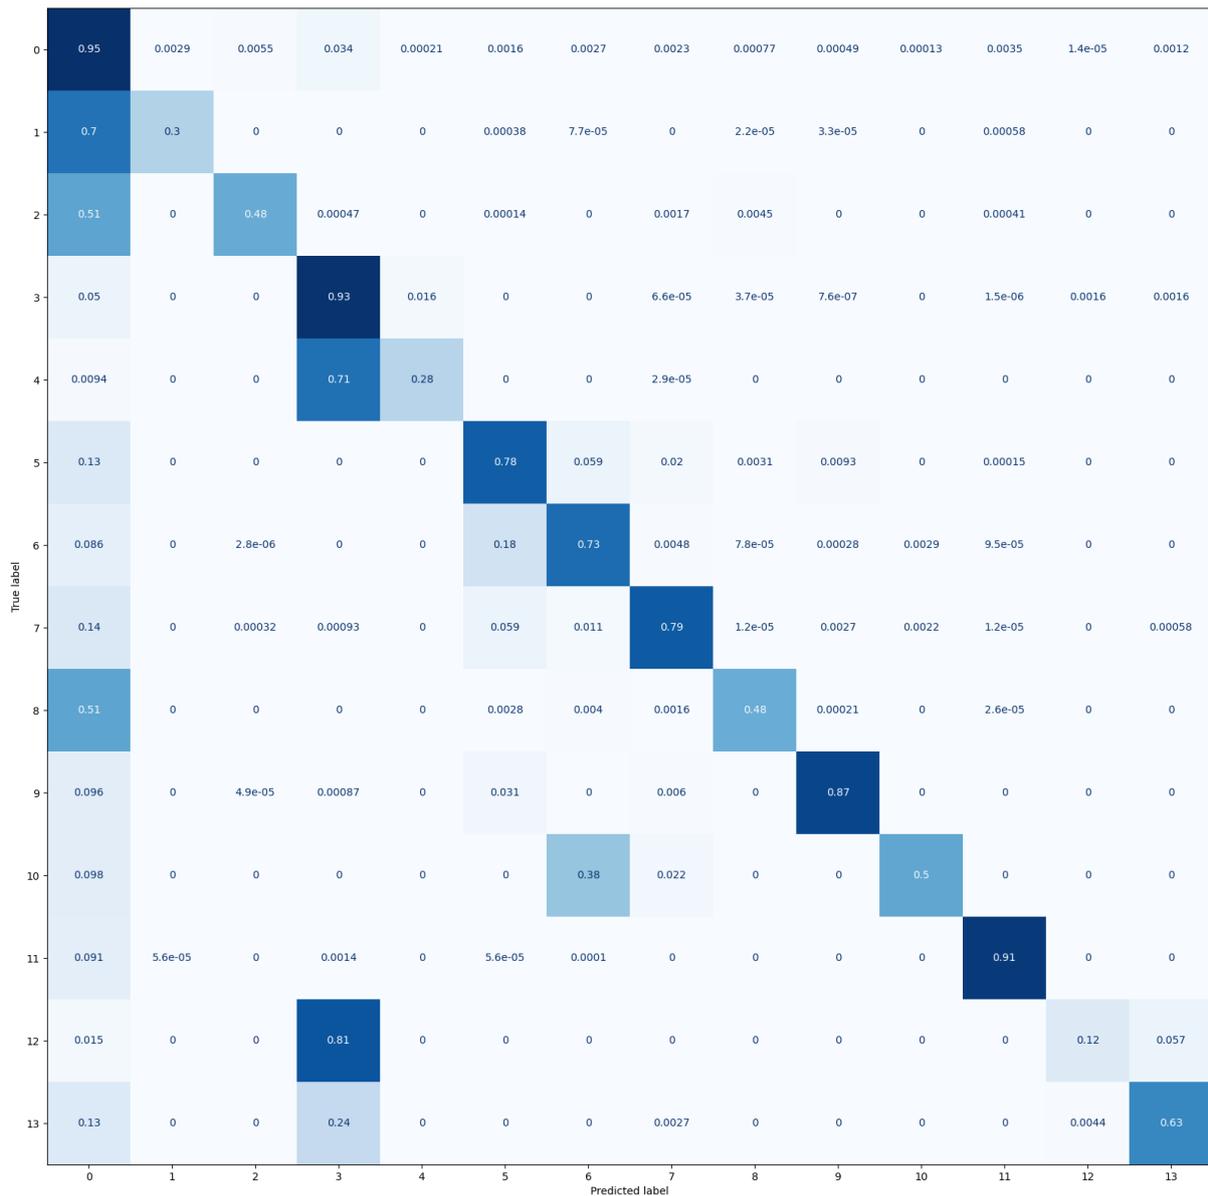


Figure 50 : Matrice de confusion (pourcentage de pixels par classe réelle)

Les labels prédits se lisent en abscisse alors que les vrais labels se lisent en ordonnée.

Les chiffres sur les deux axes correspondent aux numéros de classes que nous avons donnés. Le chiffre 8 correspond à la carie et le chiffre 0 à l'arrière-plan.

Ainsi ici, 51% des pixels de carie ont été prédits comme background alors qu'il s'agissait de carie.

3.7. Discussion

À travers cette expérimentation, plusieurs observations émergent. Les métriques présentent des résultats qui sont sujets à amélioration. Ces résultats trouvent leur origine, en partie, dans une segmentation des données qui demeure incomplète. Cette approche découle des choix méthodologiques adoptés dans le cadre de cette étude pilote.

Néanmoins, la principale limite réside dans la taille limitée du pool de données, étant donné la complexité et la lourdeur du processus de tri et de segmentation pour un individu seul.

La segmentation exhaustive de tous les labels et éléments dans les images radiographiques s'avère un travail de grande envergure pour un chercheur en solitaire.

Par conséquent, nous avons fait le choix de ne pas segmenter les parties tronquées des images. En d'autres termes, toutes les classes (dent, restauration conservatrice, etc.) qui n'étaient pas intégralement visibles sur l'image n'ont pas été segmentées. De plus, il est probable qu'il y ait eu des omissions et des classes non détectées.

Face à cette situation, deux options se sont présentées : d'une part, restreindre le nombre de radiographies étudiées pour garantir une segmentation exhaustive (A), ou d'autre part, augmenter le nombre de radiographies avec une segmentation partielle (B).

La première option aurait résulté en un ensemble de données restreint, impactant ainsi la performance du réseau de neurones.

La seconde option, malgré son absence d'effets visibles sur les métriques, aurait généré un ensemble de données plus vaste et potentiellement amélioré les performances du réseau. C'est cette deuxième option qui a été choisie et voici un exemple de répercussion.

Un exemple concret illustre cette idée :

1. Je n'ai pas segmenté un type de restauration sur une radiographie de la dent 46, bien qu'elle y soit présente.
2. L'algorithme identifie une restauration sur la dent 46.
3. Le réseau de neurones a bel et bien détecté la restauration sur la dent 46, démontrant ainsi son bon fonctionnement.
4. Néanmoins, dans le calcul des métriques, cette détection non annotée/segmentée sera perçue comme une erreur.

En termes d'amélioration de l'ensemble du projet, plusieurs pistes se dessinent :

- Le surapprentissage pourrait être atténué par une augmentation des données d'entraînement.
- Les erreurs d'annotation potentielles au sein de l'ensemble d'entraînement pourraient perturber l'apprentissage.
- Les erreurs d'annotation au sein de l'ensemble de test pourraient influencer négativement les scores.
- Une meilleure évaluation de l'indice de Jaccard sur les zones proches des contours pourrait améliorer la qualité de la segmentation, en particulier au niveau des contours.
- Une augmentation des données reproductible pourrait renforcer la diversité de l'ensemble d'entraînement.
- L'apprentissage ensembliste (ensemble learning) et l'utilisation de modèles basés sur des transformers comme "TransDeepLab: Convolution-Free Transformer-based DeepLab v3+ for Medical Image Segmentation" pourraient être explorés

Cette expérimentation avait pour objectif de créer un réseau de neurones dédié à la détection des caries dentaires sur des radiographies rétro-alvéolaires de la dent numéro 46.

Cette étude pilote s'est concentrée sur l'établissement d'un protocole méthodologique solide pour garantir des résultats cohérents. Le processus a débuté par la sélection d'un ensemble de radiographies conséquent, suivie d'une segmentation manuelle des images. Cette segmentation, réalisée à l'aide du logiciel Superannotate, a été cruciale pour établir des labels clairs et distincts pour chaque élément des radiographies.

Une phase d'essais avec différents réseaux de neurones a permis de sélectionner celui qui affichait les performances les plus prometteuses en fonction des métriques choisies. Cependant, malgré des résultats satisfaisants, il est important de noter que des améliorations restent envisageables.

Bien que l'étude confirme le potentiel de l'utilisation des réseaux de neurones pour la segmentation d'éléments anatomiques, pathologiques et thérapeutiques dans les radiographies, il n'est pas encore possible de garantir leur application clinique fiable.

Une conclusion tirée de cette étude est l'importance d'un protocole expérimental rigoureux pour garantir une précision suffisante. Les enseignements de cette étude pilote marquent le commencement d'une recherche en constante évolution. De nouvelles pistes prometteuses pourront être explorées dans les études à venir. Des erreurs ont été inévitables tout au long de cette étude.

La sélection d'un grand nombre de classes a montré ses limites, et la compréhension totale des métriques est survenue postérieurement à la publication des résultats. Il est donc impératif de réduire le nombre de labels à l'essentiel et de segmenter de manière exhaustive tous les éléments de chaque label.

Trois éléments interdépendants émergent comme cruciaux pour améliorer la pertinence des résultats et les métriques associées : l'exhaustivité de l'ensemble des radiographies, la prise en compte du contexte clinique et l'implication d'une équipe diversifiée de chirurgiens-dentistes qualifiés pour une segmentation manuelle précise.

Ces enseignements ouvrent la voie à des développements futurs visant à améliorer la pertinence de nos résultats et à renforcer l'applicabilité clinique de l'apprentissage profond dans la détection des caries dentaires sur les radiographies rétro-alvéolaires.

CONCLUSION

En conclusion de cette étude pilote qui explore l'intégration de l'apprentissage profond dans la détection des caries dentaires à partir de radiographies rétro-alvéolaires, nous faisons le bilan des résultats obtenus tout en envisageant les implications pratiques et les perspectives à venir pour le domaine clinique.

Cette étude pilote a jeté les bases pour l'application de l'apprentissage profond à la détection des caries dentaires sur les radiographies rétro-alvéolaires. Malgré des résultats prometteurs, cette exploration initiale a mis en évidence la nécessité de repenser certains aspects pour atteindre des performances plus consistantes et cliniquement pertinentes. Les perspectives d'application clinique et les défis inhérents à leur réalisation se profilent à l'horizon.

L'application clinique la plus évidente réside dans l'assistance au diagnostic des caries dentaires. En intégrant ces modèles dans la pratique des professionnels de la santé dentaire, on peut envisager une amélioration significative du dépistage précoce des caries. Cela pourrait potentiellement réduire les coûts de traitement à long terme et améliorer la prise en charge des patients.

Cependant, la faisabilité de ces applications repose sur plusieurs piliers. L'obtention d'un pool de données conséquent et diversifié, la segmentation minutieuse et la validation clinique sont des éléments clés pour garantir la fiabilité de ces modèles. La collaboration entre les experts en dentisterie et les spécialistes en apprentissage profond est essentielle pour aboutir à des solutions pertinentes sur le plan clinique.

En termes d'applications cliniques potentielles, notre étude ouvre des perspectives intéressantes.

L'assistance au diagnostic préliminaire, la détection précoce et le suivi des caries, ainsi que l'intégration dans des programmes de formation pour les professionnels de la santé dentaire, sont autant de directions possibles.

Cependant, ces applications nécessitent une infrastructure solide et une approche méthodologique rigoureuse.

La qualité des données est un élément essentiel pour la faisabilité de ces applications cliniques. Un ensemble diversifié et de haute qualité de radiographies rétro-alvéolaires est nécessaire pour garantir la généralisation solide du modèle. La

segmentation précise est fondamentale pour des résultats fiables. Cela exige des méthodes rigoureuses pour établir des labels précis et garantir la qualité de la segmentation.

Pour mettre en œuvre ces applications cliniques, une main-d'œuvre qualifiée et une collaboration multidisciplinaire sont nécessaires. Des experts en imagerie dentaire et en apprentissage profond devront travailler en tandem pour garantir une interprétation clinique pertinente et une mise en œuvre technique appropriée. De plus, une évaluation clinique approfondie sera nécessaire avant le déploiement dans un contexte clinique réel.

L'avenir de l'application clinique des modèles d'apprentissage profond pour la détection des caries dentaires est prometteur, mais il nécessite un investissement considérable en ressources humaines, en données de qualité et en validation clinique. En combinant l'expertise dentaire avec les avancées technologiques, il est possible d'imaginer un avenir où ces outils contribuent de manière significative à l'amélioration des soins dentaires et à la prise en charge précoce des caries.

En somme, cette étude pilote marque le début d'une exploration passionnante de l'utilisation de l'apprentissage profond dans le domaine dentaire. Les leçons tirées de cette étude guideront les recherches futures vers des améliorations significatives, et l'intégration de ces méthodes dans la pratique clinique nécessitera une approche soigneusement planifiée et collaborative. La synergie entre la technologie et l'expertise clinique a le potentiel de transformer la manière dont nous abordons la détection des caries dentaires et d'améliorer la santé bucco-dentaire des patients. Cependant, il reste encore beaucoup de travail à faire pour franchir le pont entre le potentiel de ces modèles et leur application clinique effective.

Plus généralement, certains voient dans les applications médicales de l'IA la possibilité de remplacer le médecin, que ce soit pour pallier les déserts médicaux ou bien pour filtrer les patients et les orienter. Mais l'utilisation par le public de ces logiciels sans supervision médicale soulève des questions éthiques importantes. Le système réduit la relation au médecin à un acte technique. Il laisse le patient à ses interrogations et ses angoisses.

Par ailleurs, le risque que le médecin abdique devant la machine « qui sait mieux que lui » est réel. Il peut être amené à endosser une décision qui n'est pas la sienne et découvrir après coup que la machine s'est trompée.

Pourtant, le médecin, doit pouvoir garder son autonomie face à la machine. Il doit être en mesure de comprendre les décisions affichées, et de les contourner si besoin.

Geoffrey Hinton, l'un des pionniers de l'IA, quitte Google et nous livre une interview qui porte sur les dangers potentiels associés à cette technologie. Hinton souligne que bien que l'IA ait un potentiel immense pour améliorer notre société mais comporte également des risques significatifs.

L'une des principales préoccupations de Hinton est que l'IA peut être utilisée à des fins malveillantes. Il craint que des acteurs mal intentionnés puissent exploiter cette technologie pour mener des attaques sophistiquées, telles que la manipulation de l'opinion publique, la création de fausses informations ou même le développement d'armes autonomes.

Hinton a également mis en garde contre le risque d'une dépendance excessive à l'IA. Il estime que si nous accordons à l'IA trop de pouvoir et de contrôle sur nos vies, nous pourrions perdre notre capacité à prendre des décisions autonomes et à comprendre les conséquences de nos actions. Il souligne l'importance de maintenir un équilibre entre l'IA et l'intelligence humaine.

Un autre point soulevé par Hinton concerne la responsabilité et la transparence de l'IA. Il est préoccupé par le manque de compréhension et de contrôle que nous pourrions avoir sur les décisions prises par les systèmes d'IA. Il insiste sur la nécessité de développer des méthodes permettant d'expliquer les résultats et les processus de l'IA de manière claire et compréhensible.

Hinton reconnaît que la recherche sur l'IA et ses applications avance rapidement, mais il estime que nous devons rester vigilants et réfléchir aux implications éthiques et sociales de cette technologie. Il appelle à un dialogue ouvert et à une collaboration entre les chercheurs, les décideurs politiques et la société dans son ensemble pour garantir que l'IA soit utilisée de manière responsable et bénéfique pour l'humanité.

L'interview de Geoffrey Hinton met en évidence les dangers potentiels associés à l'IA, notamment la possibilité d'utilisation abusive, la perte d'autonomie humaine et le manque de transparence. Tout en reconnaissant les avantages de l'IA, Hinton souligne l'importance de traiter ces questions de manière sérieuse et de mettre en place des mesures pour atténuer ces risques.

BIBLIOGRAPHIE

Références bibliographiques

1. Anthimopoulos M, Christodoulidis S, Ebner L, Christe A, Mougiakakou S. Lung Pattern Classification for Interstitial Lung Diseases Using a Deep Convolutional Neural Network. *IEEE Trans Med Imaging*. 2016; 35(5): 1207-16.
2. Becker AS, Marcon M, Ghafoor S, Wurnig MC, Frauenfelder T, Boss A. Deep Learning in Mammography: Diagnostic Accuracy of a Multipurpose Image Analysis Software in the Detection of Breast Cancer. *Invest Radiol*. 2017; 52(7): 434-40.
3. Bizopoulos P, Koutsouris D. Deep Learning in Cardiology. *IEEE Rev Biomed Eng*. 2019; 12: 168-93.
4. Cantu AG, Gehrung S, Krois J, Chaurasia A, Rossi JG, Gaudin R, et coll. Detecting caries lesions of different radiographic extension on bitewings using deep learning. *J Dent*. sept 2020;100:103425.
5. Cireşan DC, Giusti A, Gambardella LM, Schmidhuber J. Mitosis detection in breast cancer histology images with deep neural networks. *Med Image Comput Comput Assist Interv*. 2013; 16(Pt 2): 411-8.
6. Coroller TP, Grossmann P, Hou Y, Rios Velazquez E, Leijenaar RTH, Hermann G, et coll. CT-based radiomic signature predicts distant metastasis in lung adenocarcinoma. *Radiother Oncol*. 2015; 114(3): 345-50.
7. Ekert T, Krois J, Meinhold L, Elhennawy K, Emara R, Golla T, et coll. Deep Learning for the Radiographic Detection of Apical Lesions. *J Endod*. 2019; 45(7): 917-922.e5.
8. Esteva A, Robicquet A, Ramsundar B, Kuleshov V, DePristo M, Chou K, et coll. A guide to deep learning in healthcare. *Nat Med*. 2019; 25(1): 24-9.

9. Fukuda M, Inamoto K, Shibata N, Arijji Y, Yanashita Y, Kutsuna S, et coll. Evaluation of an artificial intelligence system for detecting vertical root fracture on panoramic radiography. *Oral Radiol.* 2020; 36(4): 337-43.
10. Gao X, Lin S, Wong TY. Automatic Feature Learning to Grade Nuclear Cataracts Based on Deep Learning. *IEEE Trans Biomed Eng.* 2015; 62(11): 2693-701.
11. Géron A. *Deep Learning avec Keras et Tensorflow : mise en œuvre et cas concrets.* 2^e édition. Malakoff : Dunod ; 2020. XVI-553 p.
12. Grewal PS, Oloumi F, Rubin U, Tennant MTS. Deep learning in ophthalmology: a review. *Can J Ophthalmol.* 2018; 53(4): 309-13.
13. Hiraiwa T, Arijji Y, Fukuda M, Kise Y, Nakata K, Katsumata A, et coll. A deep-learning artificial intelligence system for assessment of root morphology of the mandibular first molar on panoramic radiography. *Dentomaxillofac Radiol.* 2019; 48(3): 20180218.
14. Jiang Y, Yang M, Wang S, Li X, Sun Y. Emerging role of deep learning-based artificial intelligence in tumor pathology. *Cancer Commun (Lond).* 2020; 40(4): 154-66.
15. Kim J, Lee HS, Song IS, Jung KH. DeNTNet: Deep Neural Transfer Network for the detection of periodontal bone loss using panoramic dental radiographs. *Sci Rep.* 2019; 9(1): 17615.
16. Kusunose K, Haga A, Abe T, Sata M. Utilization of Artificial Intelligence in Echocardiography. *Circ J.* 2019; 83(8): 1623-9.
17. Kuwada C, Arijji Y, Fukuda M, Kise Y, Fujita H, Katsumata A, et coll. Deep learning systems for detecting and classifying the presence of impacted supernumerary teeth in the maxillary incisor region on panoramic radiographs. *Oral Surg Oral Med Oral Pathol Oral Radiol.* 2020; 130(4): 464-9.
18. Li S, Liu J, Zhou Z, Zhou Z, Wu X, Li Y, et coll. Artificial intelligence for caries and periapical periodontitis detection. *J Dent.* 2022; 122: 104107.

19. McBee MP, Awan OA, Colucci AT, Ghobadi CW, Kadom N, Kansagra AP, et coll. Deep Learning in Radiology. *Acad Radiol*. 2018; 25(11): 1472-80.
20. Mohammad-Rahimi H, Motamedian SR, Pirayesh Z, Haiat A, Zahedrozegar S, Mahmoudinia E, et coll. Deep learning in periodontology and oral implantology: A scoping review. *J Periodontal Res*. 2022; 57(5): 942-51.
21. Nordlinger B, Vilani C, de Fresnoye O. Médecine et intelligence artificielle. Paris : CNRS éditions ; 2022. 350 p.
22. Orhan K, Bayrakdar IS, Ezhov M, Kravtsov A, Özyürek T. Evaluation of artificial intelligence for detecting periapical pathosis on cone-beam computed tomography scans. *Int Endod J*. 2020; 53(5): 680-9.
23. Pitts NB, Zero DT, Marsh PD, Ekstrand K, Weintraub JA, Ramos-Gomez F, et coll. Dental caries. *Nat Rev Dis Primers*. 2017; 3: 17030.
24. Poorterman JHG. [Indications for and frequency of intraoral radiographs]. *Ned Tijdschr Tandheelkd*. 2015; 122(5): 272-8.
25. Schwendicke F, Elhennawy K, Paris S, Friebertshäuser P, Krois J. Deep learning for caries lesion detection in near-infrared light transillumination images: A pilot study. *J Dent*. 2020; 92: 103260.
26. Selwitz RH, Ismail AI, Pitts NB. Dental caries. *Lancet*. 2007; 369(9555): 51-9.
27. Treder M, Lauermann JL, Eter N. Automated detection of exudative age-related macular degeneration in spectral domain optical coherence tomography using deep learning. *Graefes Arch Clin Exp Ophthalmol*. 2018; 256(2): 259-65.
28. Wainberg M, Merico D, DeLong A, Frey BJ. Deep learning in biomedicine. *Nat Biotechnol*. 2018; 36(9): 829-38.
29. Whaites E, Drage N. Radiographie et radiologie dentaires. 5^e édition : Elsevier Masson ; 2019. 488 p.

30. Yasa Y, Çelik Ö, Bayrakdar IS, Pekince A, Orhan K, Akarsu S, et coll. An artificial intelligence proposal to automatic teeth detection and numbering in dental bite-wing radiographs. *Acta Odontol Scand*. 2021; 79(4): 275-281.
31. Zaharchuk G, Gong E, Wintermark M, Rubin D, Langlotz CP. Deep Learning in Neuroradiology. *AJNR Am J Neuroradiol*. 2018; 39(10): 1776-84.

Références bibliographiques électroniques

32. Ahirwar K. Everything you need to know about Neural Networks [Internet]. 2017 [consulté le 8 mai 2023]. Disponible sur: <https://hackernoon.com/everything-you-need-to-know-about-neural-networks-8988c3ee4491>
33. Akkus Z, Galimzianova A, Hoogi A, Rubin DL, Erickson BJ. Deep Learning for Brain MRI Segmentation: State of the Art and Future Directions. *J Digit Imaging* [Internet]. 2017 [cité 4 mai 2023]; 30(4): 449-59. Disponible sur: <https://doi.org/10.1007/s10278-017-9983-4>
34. Boone J, Goodin C, Dabbiru L, Hudson C, Cagle L, Carruth D. Training Artificial Intelligence Algorithms with Automatically Labelled UAV Data from Physics-Based Simulation Software. *Applied Sciences* [Internet]. 2023 [cité 8 mai 2023]; 13(1): 131. Disponible sur: <https://www.mdpi.com/2076-3417/13/1/131>
35. Casalegno F, Newton T, Daher R, Abdelaziz M, Lodi-Rizzini A, Schürmann F, et coll. Caries Detection with Near-Infrared Transillumination Using Deep Learning. *J Dent Res* [Internet]. 2019 [cité 3 sept 2023]; 98(11): 1227-33. Disponible sur: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6761787/>
36. Chatelain C, Hérault R. Découvrez le neurone formel [Internet]. 2021 [consulté le 8 mai 2023]. Disponible sur : <https://openclassrooms.com/fr/courses/5801891-initiez-vous-au-deep-learning/5801898-decouvrez-le-neurone-formel>

37. Currie G, Hawk KE, Rohren E, Vial A, Klein R. Machine Learning and Deep Learning in Medical Imaging: Intelligent Imaging. *Journal of Medical Imaging and Radiation Sciences* [Internet]. 2019 [cité 5 mai 2023]; 50(4): 477-87. Disponible sur: [https://www.jmirs.org/article/S1939-8654\(19\)30504-1/fulltext](https://www.jmirs.org/article/S1939-8654(19)30504-1/fulltext)
38. DataScientest. Convolutional Neural Network ou réseaux de neurones convolutifs [Internet]. 2020 [consulté le 8 mai 2023]. Disponible sur: <https://datascientest.com/convolutional-neural-network>
39. Esteva A, Kuprel B, Novoa RA, Ko J, Swetter SM, Blau HM, et coll. Dermatologist-level classification of skin cancer with deep neural networks. *Nature* [Internet]. 2017 [cité 8 mai 2023]; 542(7639): 115-8. Disponible sur: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC8382232/>
40. Fidle. History and basics concepts [Internet]. 2022 [cité 1 juin 2023]. Disponible sur : <https://cloud.univ-grenoble-alpes.fr/s/wxCztjYBbQ6zwd6>
41. Ghaffari A, Savaria Y. CNN2Gate: An Implementation of Convolutional Neural Networks Inference on FPGAs with Automated Design Space Exploration. *Electronics* [Internet]. 2020 [cité 8 mai 2023]; 9(12): 2200. Disponible sur: <https://www.mdpi.com/2079-9292/9/12/2200>
42. INSERM (Institut national de la santé et de la recherche médicale). Intelligence artificielle et santé : Des algorithmes au service de la médecine [Internet]. 2018 [consulté le 27 avr 2023]. Disponible sur : <https://www.inserm.fr/dossier/intelligence-artificielle-et-sante/>
43. Kamioner P. Radio rétro-alvéolaire : son intérêt et son coût [Internet]. 2023 [consulté le 2 mai 2023]. Disponible sur : <https://www.drkamioner.fr/lexique-dentaire/radiographie-retro-alveolaire>
44. Khanagar SB, Al-Ehaideb A, Vishwanathaiah S, Maganur PC, Patil S, Naik S, et coll. Scope and performance of artificial intelligence technology in orthodontic diagnosis, treatment planning, and clinical decision-making: A systematic review. *J Dent Sci* [Internet]. 2021 [cité 27 avr 2023]; 16(1): 482-92. Disponible sur: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7770284/>

45. de Koning HJ, van der Aalst CM, de Jong PA, Scholten ET, Nackaerts K, Heuvelmans MA, et coll. Reduced Lung-Cancer Mortality with Volume CT Screening in a Randomized Trial. *N Engl J Med* [Internet]. 2020 [cité 5 mai 2023]; 382(6): 503-13. Disponible sur: <https://www.nejm.org/doi/10.1056/NEJMoa1911793>
46. Lee H, Tajmir S, Lee J, Zissen M, Yeshiwas BA, Alkasab TK, et coll. Fully Automated Deep Learning System for Bone Age Assessment. *J Digit Imaging* [Internet]. 2017 [cité 4 mai 2023]; 30(4): 427-41. Disponible sur: <https://doi.org/10.1007/s10278-017-9955-8>
47. Lee S, Oh S il, Jo J, Kang S, Shin Y, Park J won. Deep learning for early dental caries detection in bitewing radiographs. *Sci Rep* [Internet]. 2021 [cité 3 sept 2023]; 11(1): 16807. Disponible sur: <https://www.nature.com/articles/s41598-021-96368-7>
48. Lian L, Zhu T, Zhu F, Zhu H. Deep Learning for Caries Detection and Classification. *Diagnostics* [Internet]. 2021 [cité 3 sept 2023]; 11(9): 1672. Disponible sur: <https://www.mdpi.com/2075-4418/11/9/1672>
49. Lin S, Li Z, Fu B, Chen S, Li X, Wang Y, et coll. Feasibility of using deep learning to detect coronary artery disease based on facial photo. *Eur Heart J* [Internet]. 2020 [cité 4 mai 2023]; 41(46): 4400-11. Disponible sur: <https://doi.org/10.1093/eurheartj/ehaa640>
50. Maurice B. Fonctionnement du neurone artificiel [Internet]. 2018 [consulté le 8 mai 2023]. Disponible sur : <https://deeplylearning.fr/cours-theoriques-deep-learning/fonctionnement-du-neurone-artificiel/>
51. Muhammad H, Fuchs TJ, De Cuir N, De Moraes CG, Blumberg DM, Liebmann JM, et coll. Hybrid deep learning on single wide-field optical coherence tomography scans accurately classifies glaucoma suspects. *J Glaucoma* [Internet]. 2017 [cité 8 mai 2023]; 26(12): 1086-94. Disponible sur: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC5716847/>

52. Muller O, Abbé E, Mach F. L'intelligence artificielle et la cardiologie : la machine est lancée. Rev Med Suisse [Internet]. 2022 [cité 22 mars 2023]; 783: 1027-8. Disponible sur: <https://www.revmed.ch/revue-medicale-suisse/2022/revue-medicale-suisse-783/l-intelligence-artificielle-et-la-cardiologie-la-machine-est-lancee>
53. Okada K, Rysavy S, Flores A, Linguraru MG. Noninvasive differential diagnosis of dental periapical lesions in cone-beam CT scans. Med Phys [Internet]. 2015 [cité 4 mai 2023]; 42(4): 1653-65. Disponible sur: <https://onlinelibrary.wiley.com/doi/abs/10.1118/1.4914418>
54. Pérez-Enciso M, Zingaretti LM. A Guide on Deep Learning for Complex Trait Genomic Prediction. Genes (Basel) [Internet]. 2019 [cité 8 mai 2023]; 10(7): 553. Disponible sur: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6678200/>
55. PetitPas L, Weissenbach O, Makaremi M, Bouletreau P. L'intelligence artificielle au service des protocoles orthodontico-chirurgicaux: Artificial Intelligence: applications in orthognathic surgery. Rev. Orthop. Dento-fac. [Internet]. 2021 [cité 14 mai 2022] ; 55(1) : 89-104. Disponible sur: <http://search.ebscohost.com/bases-doc.univ-lorraine.fr/login.aspx?direct=true&AuthType=ip,url,uid&db=ddh&AN=150849099&lang=fr&site=ehost-live>
56. Reduced Lung-Cancer Mortality with Low-Dose Computed Tomographic Screening. N Engl J Med [Internet]. 2011 [cité 5 mai 2023]; 365(5): 395-409. Disponible sur: <https://www.nejm.org/doi/10.1056/NEJMoa1102873>
57. Rousseau D, Douarre C. Introduction à l'apprentissage profond (deep learning) de l'intelligence artificielle [Internet]. 2021 [consulté le 8 mai 2023]. Disponible sur: <https://culturesciencesphysique.ens-lyon.fr/ressource/IA-apprentissage-Rousseau.xml>

58. Tixier F, Rest CCL, Hatt M, Albarghach N, Pradier O, Metges JP, et coll. Intratumor Heterogeneity Characterized by Textural Features on Baseline 18F-FDG PET Images Predicts Response to Concomitant Radiochemotherapy in Esophageal Cancer. *J Nucl Med* [Internet]. 2011 [cité 25 avr 2023]; 52(3): 369-78. Disponible sur: <https://jnm.snmjournals.org/content/52/3/369>
59. Tran KA, Kondrashova O, Bradley A, Williams ED, Pearson JV, Waddell N. Deep learning in cancer diagnosis, prognosis and treatment selection. *Genome Med* [Internet]. 2021 [cité 8 mai 2023]; 13: 152. Disponible sur: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC8477474/>
60. Trivedi A. Deep Learning Part 2: Transfer learning and fine-tuning deep convolutional neural networks [Internet]. 2016 [consulté le 8 mai 2023]. Disponible sur: <https://blog.revolutionanalytics.com/2016/08/deep-learning-part-2.html>
61. Tsiknakis N, Theodoropoulos D, Manikis G, Ktistakis E, Boutsora O, Berto A, et coll. Deep learning for diabetic retinopathy detection and classification based on fundus images: A review. *Comput Biol Med* [Internet]. 2021 [cité 4 mai 2023]; 135: 104599. Disponible sur: <https://www.sciencedirect.com/science/article/pii/S0010482521003930>

ANNEXE : CODE SOURCE SUR GITHUB

https://gitlab.com/ds8115635/segmentation_molaire

TABLE DES MATIÈRES

| | |
|---|----|
| SOMMAIRE | 8 |
| LISTE DES FIGURES | 9 |
| LISTE DES TABLEAUX | 11 |
| LISTE DES ABRÉVIATIONS | 12 |
| INTRODUCTION | 13 |
| 1. L'APPRENTISSAGE PROFOND DANS L'ANALYSE D'IMAGE PAR ORDINATEUR | 15 |
| 1.1. Définitions et généralités..... | 15 |
| 1.2. Les réseaux de neurones profonds..... | 21 |
| 1.3. Analyse d'image par apprentissage profond..... | 24 |
| 1.3.1. La couche de convolution..... | 24 |
| 1.3.2. La couche de pooling..... | 26 |
| 1.3.3. Les hyperparamètres..... | 27 |
| 1.3.4. La couche fully connected..... | 28 |
| 1.3.5. Exemple d'analyse d'image par apprentissage profond..... | 28 |
| 1.4. Historique..... | 30 |
| 1.5. Utilisation en santé..... | 32 |
| 1.5.1. En médecine..... | 33 |
| 1.5.2. En odontologie..... | 38 |
| 1.6. Avantages..... | 46 |
| 1.7. Limites..... | 50 |
| 1.8. Applications futures..... | 54 |
| 2. RADIOGRAPHIE RÉTRO-ALVÉOLAIRE ET LÉSION DENTAIRE | 56 |
| 2.1. La carie dentaire..... | 56 |
| 2.2. La radiographie rétro-alvéolaire..... | 58 |
| 2.2.1. Définitions et généralités..... | 58 |
| 2.2.2. Indications..... | 58 |
| 2.2.3. Limites..... | 59 |

| | |
|--|-----|
| 2.2.4. Visualisation des structures anatomo-pathologiques..... | 60 |
| 3. EXPÉRIMENTATION | 61 |
| 3.1. Matériels et méthodes..... | 61 |
| 3.2. Logigramme | 62 |
| 3.3. Récolte et tri des données | 63 |
| 3.4. Segmentation des données | 63 |
| 3.4.1. Définitions/Généralités | 63 |
| 3.4.2. Stratégie de labellisation par opérateur | 64 |
| 3.4.3. Choix des labels | 64 |
| 3.4.4. Exemple de segmentation | 68 |
| 3.5. Création du modèle algorithmique | 70 |
| 3.5.1. Schéma des étapes de création | 70 |
| 3.5.2. Définitions et généralités | 70 |
| 3.5.3. Préparation du jeu de données | 71 |
| 3.5.4. Les traitements opérés sur l'image..... | 73 |
| 3.5.5. Test des différents modèles et paramètres par validation croisée..... | 78 |
| 3.6. Résultats | 82 |
| 3.6.1. Métriques retenues et définitions..... | 82 |
| 3.6.2. Résultats tableaux..... | 84 |
| 3.6.3. Résultats par l'image du RNA | 85 |
| 3.6.4. Matrice de confusion | 89 |
| 3.7. Discussion..... | 93 |
| CONCLUSION | 96 |
| BIBLIOGRAPHIE | 99 |
| Références bibliographiques..... | 99 |
| Références bibliographiques électroniques | 102 |
| ANNEXE : Code source sur Github..... | 107 |

GERMAIN Simon – Détection des lésions dentaires sur radiographie rétro-alvéolaire par apprentissage profond : une étude pilote.

Nancy 2023 : 109 pages. 50 figures, 1 tableau.

Th. : Chir.-Dent. : Nancy 2023

Mots clefs :

- *Apprentissage profond – Deep Learning*
- *Radiographie - Radiography*
- *Carie dentaire – Dental Decay*
- *Intelligence Artificielle – Artificial Intelligence*

Résumé :

L'apprentissage profond est une sous partie de l'intelligence artificielle et est construit autour du développement de réseaux de neurones artificiels qui permettent de catégoriser automatiquement des ensembles de données.

Ce travail permet de définir de manière générale le fonctionnement des algorithmes d'apprentissage profond.

Ce travail propose également d'exposer les différents domaines d'action de l'apprentissage profond en médecine et plus particulièrement en odontologie. Il nous permet aussi d'en voir ses perspectives futures, ses avantages et ses limites.

Cette étude pilote avait pour objectif de créer un réseau de neurones convolutifs capable de segmenter les lésions carieuses en secteur 4. Un protocole a été mis en place pour créer cet algorithme et obtenir des résultats.

Nous commencerons par des définitions et des généralités sur l'apprentissage profond dans l'analyse d'image par ordinateur puis nous détaillerons la radiographie rétro-alvéolaire et les lésions carieuses et enfin, nous décrirons le protocole d'expérimentation que nous avons mené concernant la création d'un réseau de neurones pour la détection de lésion dentaire par apprentissage profond.

Jury :

| | |
|--------------------------|-----------------------|
| Président : | Pr Éric MORTIER |
| Membre : | Dr Morgane HOMBOURGER |
| Co-directeurs de thèse : | Dr David JOSEPH |
| | Dr Kazutoyo YASUKAWA |

Adresse de l'auteur :

Simon GERMAIN
20, avenue de la Malgrange
54140 Jarville-la-Malgrange