



HAL
open science

Segmentation de lésions carieuses à partir de radiographies par un réseau de neurones à convolution

Van-Hoan Nguyen

► **To cite this version:**

Van-Hoan Nguyen. Segmentation de lésions carieuses à partir de radiographies par un réseau de neurones à convolution. Sciences du Vivant [q-bio]. 2021. dumas-03451688

HAL Id: dumas-03451688

<https://dumas.ccsd.cnrs.fr/dumas-03451688>

Submitted on 26 Nov 2021

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.

U.F.R. des Sciences Odontologiques

Année 2021

Thèse n°78

THESE POUR L'OBTENTION DU

**DIPLOME D'ETAT de DOCTEUR EN CHIRURGIE
DENTAIRE**

Présentée et soutenue publiquement

Par NGUYEN Van-Hoan

Né le 24/05/1997 à Bordeaux

Le 18 Novembre 2021

**Segmentation de lésions carieuses à partir de
radiographies par un réseau de neurones à convolution**

Sous la direction de : Yves DELBOS

Membres du jury :

M DEVILLARD Raphaël
M DELBOS Yves
Mme CHUY Virginie
M BOU Christophe

Professeur des Universités
Maître de Conférences des Universités
Assistante Hospitalo-Universitaire
Maître de Conférences des Universités

Président
Directeur
Rapporteur
Assesseur

UNIVERSITE DE BORDEAUX

Président
Directeur de Collège des Sciences de la Santé

M. TUNON DE LARA Manuel
M. PELLEGRIN Jean-Luc

COLLEGE DES SCIENCES DE LA SANTE **UNITE DE FORMATION ET DE RECHERCHE DES SCIENCES ODONTOLOGIQUES**

Directrice	Mme BERTRAND Caroline	58-01
Directeur Adjoint à la Pédagogie	Mr DELBOS Yves	56-01
Directeur Adjoint – Chargé de la Recherche	M. CATROS Sylvain	57-01
Directeur Adjoint – Chargé des Relations Internationales	M. SEDARAT Cyril	57-01

ENSEIGNANTS DE L'UFR

PROFESSEURS DES UNIVERSITES

Mme	Caroline	BERTRAND	Prothèse dentaire	58-01
Mme	Marie-José	BOILEAU	Orthopédie dento-faciale	56-01
M	Sylvain	CATROS	Chirurgie orale	57-01
M	Raphaël	DEVILLARD	Dentisterie restauratrice et endodontie	58-01
Mme	Véronique	DUPUIS	Prothèse dentaire	58-01
M.	Bruno	ELLA NGUEMA	Sciences anatomiques et physiologiques - Biomatériaux	58-01
M.	Jean-Christophe	FRICAIN	Chirurgie buccale – Pathologie et thérapeutique	57-01

MAITRES DE CONFERENCES DES UNIVERSITES

Mme	Elise	ARRIVÉ	Prévention épidémiologie – Economie de la santé – Odontologie légale	56-02
Mme	Audrey	AUSSEL	Sciences anatomiques et physiologiques	58-01
Mme	Cécile	BADET	Biologie Orale	57-01
M.	Etienne	BARDINET	Orthopédie dento-faciale	56-01
M.	Michel	BARTALA	Prothèse dentaire	58-01
M.	Cédric	BAZERT	Orthopédie dento-faciale	56-01
M.	Christophe	BOU	Prévention épidémiologie – Economie de la santé – Odontologie légale	56-02
Mme	Sylvie	BRUNET	Chirurgie buccale – Pathologie et thérapeutique	57-01
M.	Jacques	COLAT PARROS	Sciences anatomiques et physiologiques	58-01
M,	Jean-Christophe	COUTANT	Sciences anatomiques et physiologiques	58-01
M.	François	DARQUE	Orthopédie dento-faciale	56-01
M.	François	DE BRONDEAU	Orthopédie dento-faciale	56-01
M.	Yves	DELBOS	Odontologie pédiatrique	56-01
M,	Emmanuel	D'INCAU	Prothèse dentaire	58-01
Mme	Mathilde	FENELON	Chirurgie Orale	57-01
Mme	Elsa	GAROT	Odontologie pédiatrique	56-01
M.	Dominique	GILLET	Dentisterie restauratrice et endodontie	58-01
Mme	Olivia	KEROUREDAN	Dentisterie restauratrice et endodontie	58-01
M.	Jean-François	LASSERRE	Prothèse dentaire	58-01
M.	Yves	LAUVERJAT	Parodontologie	57-01
M.	Adrien	NAVEAU	Prothèse dentaire	58-01
M.	Philippe	POISSON	Prévention épidémiologie – Economie de la santé – Odontologie légale	56-02
M.	Patrick	ROUAS	Odontologie pédiatrique	56-01
M.	Johan	SAMOT	Biologie Orale	57-01
Mme	Maud	SAMPEUR	Orthopédie dento-faciale	56-01
M.	Cyril	SEDARAT	Parodontologie	57-01
Mme	Noélie	THEBAUD	Biologie Orale	57-01
M.	Eric	VACHEY	Dentisterie restauratrice et endodontie	58-01

AUTRES ENSEIGNANTS

M.	Cédric	FALLA	Prévention épidémiologie – Economie de la santé – Odontologie légale	56-02
M.	François	ROUZÉ L'ALZIT	Prothèse dentaire	58-01

ASSISTANTS

M.	Bastien	BERCAULT	Chirurgie Orale	57-01
M.	Baptiste	BERGES	Prothèse dentaire	58-01
Mme	Mathilde	BOUDEAU	Odontologie conservatrice – Endodontie	58-01
Mme	Virginie	CHUY	Prévention épidémiologie – Economie de la santé – Odontologie légale	56-02
M	Pierre-Hadrien	DECAUP	Prothèse dentaire	58-01
Mme	Laura	DONNET	Biologie Orale	57-01
Mme	Julia	ESTIVALS	Odontologie pédiatrique	56-01
Mme	Laurie	FUCHS	Odontologie pédiatrique	56-01
Mr	Pierre-André	GUILLAUD	Parodontologie	57-01
Mme	Jane	GOURGUES	Prévention épidémiologie – Economie de la santé – Odontologie légale	56-02
Mr	Louis	HUAULT	Sciences anatomiques et physiologiques	58-01
Mme	Mathilde	JACQUEMONT	Parodontologie	57-01
Mme	Clémence	JAECK	Prothèse dentaire	58-01
Mr	Aymeric	JOUBERT DU CELLIER	Dentisterie restauratrice et endodontie	58-01
Mr	Jean-Baptiste	IRIBARREN	Dentisterie restauratrice et endodontie	58-01
Mme	Claudine	KHOURY	Prévention épidémiologie – Economie de la santé – Odontologie légale	56-02
Mme	Camille	LACAULE	Orthopédie dento-faciale	56-01
M.	Antoine	LAFITTE	Orthopédie dento-faciale	56-01
Mme	Léa	MASSE	Prothèse dentaire	58-01
Mme	Aude	MENARD	Prothèse dentaire	58-01
M	Florian	PITEU	Prothèse dentaire	58-01
Mme	Rawen	SMIRANI	Parodontologie	57-01
Mme	Florianne	VILLAT	Dentisterie restauratrice et endodontie	58-01
M.	Clément	VACHEY	Odontologie conservatrice – Endodontie	58-01
M	Paul	VITIELLO	Prothèse dentaire	58-01
Mme	Sophia	ZIANE	Odontologie conservatrice – Endodontie	58-01

Remerciements

A notre Président de thèse

Monsieur le Professeur Raphaël DEVILLARD
Professeur des Universités – Praticien Hospitalier
Section Dentisterie restauratrice et endodontie 58-01

Je vous remercie pour l'honneur que vous me faites en acceptant de présider le jury de cette thèse.

Ce travail exprime ma sincère reconnaissance et mon respect pour la qualité de votre enseignement ainsi que pour la qualité de votre encadrement au sein de l'hôpital Pellegrin.

A notre Directeur de thèse

Monsieur le Docteur Yves DELBOS
Maître de Conférences des Universités – Praticien Hospitalier
Directeur adjoint à la pédagogie
Section Odontologie Pédiatrique – 56-01

Je vous remercie sincèrement d'avoir accepté la direction de cette thèse et de m'avoir fait confiance tout du long de ce travail en m'apportant votre soutien et vos précieux conseils.

Je vous suis également reconnaissant pour tout l'encadrement dont j'ai pu bénéficier à vos côtés lors de mon externat.

A notre Rapporteur de thèse

Madame la Docteure Virginie CHUY

Assistante Hospitalo-Universitaire

Section Prévention épidémiologique – Économie de la santé – Odontologie légale

Je vous remercie sincèrement pour l'intérêt que vous avez porté à ma thèse ainsi que pour vos conseils et la disponibilité que vous avez portée à mon égard.

Merci d'avoir contribué à ma formation et d'avoir accepté de participer à ce jury en tant que rapporteur.

A notre Assesseur

Monsieur le Docteur Christophe BOU

Maître de Conférences des Universités – Praticien Hospitalier

Section Prévention épidémiologique – Économie de la santé – Odontologie légale

Je vous suis reconnaissant pour l'intérêt que vous portez à cette thèse et pour la qualité de votre encadrement lors de ma formation et de mon externat.

Je vous remercie d'avoir accepté de participer à ce jury.

Table des matières

I.Introduction.....	8
A.La radiographie intra-buccale dans la détection des caries.....	8
1.Définition de la carie.....	8
2.La radiographie intra-buccale.....	8
3.Artefacts.....	9
a.Translucidité cervicale.....	9
b.Bandes de Mach.....	10
B.L'intelligence artificielle en santé.....	11
1.Machine learning.....	11
2.Deep learning.....	11
3.Apprentissages.....	12
a.Apprentissage supervisé.....	12
b.Apprentissage non-supervisé.....	12
c.Apprentissage semi-supervisé.....	12
d.Apprentissage par renforcement.....	12
4.Réseau de neurones à convolution.....	13
a.Diminution de la fonction de coût.....	13
b.Sur et sous-apprentissage.....	14
b.1.Sur-apprentissage.....	14
b.2.Sous-apprentissage.....	14
c.Vitesse d'apprentissage.....	15
5.Transformations d'une image.....	16
a.Classification.....	16
b.Détection.....	16
c.Segmentation.....	17
C.L'intelligence artificielle en odontologie.....	18
D.Introduction à l'étude.....	19
II.Matériel et Méthodes.....	20
A.Collecte des données.....	20
B.Répartition des données.....	21
1.Data set.....	21
2.Test set.....	22
C.Segmentation des lésions carieuses.....	23
D.Programmation du réseau et pré processing.....	24
E.Augmentation des données.....	25
F.Analyse Statistique.....	26
1.Classification des pixels.....	26
2.Matrice de confusion.....	26
3.Sensibilité, spécificité, précision.....	27
4.Coefficient de Dice.....	27
5.Fonction d'efficacité du récepteur et aire sous la courbe.....	28
III.Résultats.....	29
A.Fonction de coût.....	29
B.Métriques.....	29
C.Matrices de confusion.....	30
D.Fonctions d'efficacité du récepteur.....	32
IV.Discussion.....	33
A.Analyse des résultats.....	33
B.Limites de l'étude.....	34

C.Forces de l'étude.....	35
V.Conclusion.....	36
Bibliographie.....	37
Annexe	39

Index des illustrations

Illustration 1: Translucidité cervicale.....	9
Illustration 2: Effet Mach Band.....	10
Illustration 3: Exemple de classification.....	16
Illustration 4: Exemple de détection d'objet.....	16
Illustration 5: Exemple de segmentation d'objets, sémantique à gauche, d'instance à droite.....	17
Illustration 6: Application d'un réseau de neurones à convolution pour la segmentation d'une dent à partir d'une image issue d'une caméra par transillumination	18
Illustration 7: Exemple de radiographies incluses dans l'étude.....	20
Illustration 8: Exemple de segmentation d'une carie.....	23
Illustration 9: Génération du masque à partir d'une radiographie segmentée.....	24
Illustration 10: Exemple des modifications d'une image.....	25

Index des figures

Figure 1: Schéma simplifié d'un réseau de neurones à convolution.....	13
Figure 2: Exemple de fonctions loss en fonction du nombre d'epoch.....	14
Figure 3: Schéma de sous et sur-apprentissage.....	14
Figure 4: Schéma simplifié des différents learning rate.....	15
Figure 5: Classification des pixels en fonction du diagnostic.....	26
Figure 6: Fonction de coût.....	29
Figure 7: Exemple de matrice de confusion.....	30
Figure 8: Matrice de confusion pour les différents groupes et le total.....	31
Figure 9: Fonction d'efficacité du récepteur et aire sous la courbe de différents groupes et du total..	32

Index des tableaux

Tableau 1: Composition du data set.....	21
Tableau 2: Composition du test set.....	22
Tableau 3: Exemple de matrice de confusion.....	26
Tableau 4: Valeurs de précision, sensibilité, spécificité, indice de Dice et AUC pour la segmentation des lésions carieuses dans les différents groupes et le total.....	29

I. Introduction

A. La radiographie intra-buccale dans la détection des caries

1. Définition de la carie

La carie dentaire est une maladie chronique largement répandue, affectant plus de 3,5 milliards d'adultes dans le monde et plus de 530 millions d'enfants selon les rapports de l'Organisation Mondiale de la Santé [1].

Il s'agit d'une déminéralisation des tissus dentaires suite au relargage d'acide par les bactéries de la plaque dentaire. Le terme carie décrit à la fois le processus carieux, invisible et la lésion carieuse potentiellement visible à un instant t [2].

Le diagnostic des caries nécessite donc de retrouver ces deux aspects : détecter la lésion carieuse et déterminer l'activité du processus carieux, arrêté ou actif [3].

2. La radiographie intra-buccale

Les radiographies intra-buccales sont un examen complémentaire fréquent dans la détection et la prévention des caries. Faciles à réaliser au fauteuil et rapide à mettre en œuvre, tous les cabinets dentaires en France sont équipés d'un dispositif de radiographies intra-buccales.

L'image obtenue après développement de la radiographie permet au praticien de disposer d'une vue en deux dimensions de la zone radiographiée, permettant d'évaluer les zones non-visibles lors de l'examen clinique comme les zones inter-proximales, l'os alvéolaire ou l'intérieur de la dent.

Les radiographies utilisées en odontologie ne permettent pas le diagnostic des caries car il est impossible de déterminer l'activité du processus carieux sur une seule radiographie. Elles permettent néanmoins dans certains cas la détection des lésions carieuses, dont certaines invisibles lors du sondage.

La détection des caries sur les radiographies dépend de la qualité de la radiographie.

Une radiographie correctement angulée, sans flou de mouvement et avec l'exposition recommandée par le fabricant de l'appareil permet d'obtenir une radiographie interprétable dans la majorité des cas.

De nos jours, la plupart des radiographies prises sont numériques, soit avec un capteur à l'état solide soit avec une plaque au phosphore.

Le traitement numérique va permettre de retoucher l'image obtenue afin d'optimiser au mieux les paramètres de l'image numérique pour lire la radiographie. Les modifications possibles varient selon le matériel utilisé mais il est le plus souvent possible de :

- modifier le contraste
- modifier la luminosité
- inverser l'image
- zoomer sur une zone.

Ces modifications des paramètres de l'image permettent de corriger différents défauts lors de la prise de la radiographie.

La détection des lésions carieuses sur une radiographie intra-buccale se caractérise par l'observation d'une zone radio-claire dans l'émail, la dentine ou le cément suite à leur déminéralisation par l'acide rejeté par les bactéries du biofilm. Cette zone d'ombre radio-claire prend souvent l'apparence d'une soucoupe [4].

Cette zone radio-claire peut être partiellement plus radio-claire que le tissu d'origine sain adjacent indiquant la présence d'autre tissus superposé 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 de voir à la radiographie un liséré radio-opaque le long des contours de la déminéralisation, il s'agit de dentine tertiaire produite suite à l'agression [4].

3. Artefacts

Deux artefacts peuvent conduire à la mauvaise détection des caries [4][5].

a. Translucidité cervicale

La translucidité cervicale, appelée « cervical burn-out » en anglais, est un phénomène physique lié à l'anatomie des dents ainsi qu'à la pénétration variable des rayons X.

La région cervicale, composée uniquement de dentine est une zone où le faisceau de rayons X aura le moins de tissu à traverser donc apparaîtra radio-claire à la radiographie, imitant l'aspect d'une lésion carieuse (Illustration 1).

Il est possible de différencier la translucidité cervicale d'une lésion carieuse à travers les éléments suivants :

- La localisation : l'étendue de l'effet de cervical burn-out se limite en coronaire par le niveau de l'émail et en apical par l'os alvéolaire alors qu'une lésion carieuse peut progresser au-delà de ces limites.
- La morphologie de la lésion : la translucidité prend une forme triangulaire devenant progressivement moins apparente en allant en direction de la pulpe alors que les lésions carieuses sont d'aspect généralement plus arrondi.
- La récurrence : les dents similaires sont touchées par cet artefact sur la même radiographie, particulièrement les prémolaires de taille réduite compte tenu de leur morphologie.



Illustration 1: Translucidité cervicale

b. Bandes de Mach

L'effet « Mach Band », les bandes de Mach en français, est un effet de la loi du contraste simultané des couleurs. Entre deux surfaces de clarté différente, deux bandes étroites apparaissent augmentant la différence entre les deux teintes. La surface la plus claire est bordée par une bande plus claire et la plus sombre par une bande plus sombre. L'observation de ces bandes sur un fond neutre permet de se rendre compte qu'il n'y a aucune différence par rapport aux zones claire et sombre initiales.

On retrouve cet effet d'optique dans les radiographies dentaires, à la jonction entre l'émail et la dentine faisant apparaître une zone radio-claire dans la zone dentinaire en contact avec l'émail. Les prémolaires sont plus souvent touchées par ce phénomène de par leur morphologie. Ces bandes de Mach peuvent être confondues avec des lésions carieuses dentinaires (Illustration 2).

Pour les distinguer, il est possible de cacher avec un bout de papier la zone d'émail au-dessus de la zone dentinaire suspectée pour faire disparaître les bandes de Mach.

La présence ou l'absence de lésions énamélaires sur la dent peut également influencer sur les chances d'avoir une véritable lésion carieuse.

Enfin tous les observateurs n'ont pas la même habilité à percevoir les bandes de Mach et la perception est modifiée par la projection, les contours ainsi que le capteur et la densité des objets.



Illustration 2: Effet Mach Band

Les deux artefacts que sont la translucidité cervicale ainsi que les bandes de Mach peuvent conduire à la mauvaise détection des lésions carieuses en sur-diagnostiquant des lésions. L'interprète des radiographies doit être capable de les différencier et seul l'examen clinique avec le sondage permettra le diagnostic des caries dentaires.

B. L'intelligence artificielle en santé

L'intelligence artificielle représente l'ensemble des théories et des techniques mises en œuvre afin de concevoir des machines capables d'imiter une intelligence réelle. Une approche considérée comme « manuelle » revient à coder l'intégralité des éventualités et des actions qu'elle peut et doit réaliser. Cette approche nécessite énormément de temps et peut être peu pertinente dans certaines situations.

A titre d'exemple, programmer une intelligence capable de ne jamais perdre au jeu d'échec impliquerait de lui apprendre les règles du jeu : les déplacements propres à chaque pièce et les prises de pièces adversaires possibles mais également d'être prête à chaque éventualité. Le jeu d'échec comporte dès le deuxième tour 20 000 possibilités de déplacements différentes et 10^{120} parties différentes sont possibles au total, programmer manuellement une intelligence avec toutes les possibilités codées est impossible à l'échelle humaine actuellement.

L'intelligence artificielle est mise en œuvre dans le domaine médical depuis plusieurs années grâce aux progrès technologiques qui ont été réalisés. Parmi eux, on trouve :

- L'augmentation de la quantité de données disponible
- L'augmentation de la puissance de calcul
- Le développement des outils et du niveau d'abstraction qui a permis de rendre l'intelligence artificielle plus accessible aux développeurs.

Ces avancées ont permis l'analyse d'un très grand nombre de données et la mise en place de modèles prédictifs. Cette application de l'intelligence artificielle s'est retrouvée dans le domaine de la santé en raison du nombre important de données patient qu'il est désormais possible d'enregistrer et de monitorer ainsi que du besoin d'analyser ces données de manière reproductible. Cette analyse des données veut à terme proposer une meilleure prise en charge du patient et une meilleure précision dans le diagnostic de certaines maladies.

1. Machine learning

Le machine learning est un sous ensemble de l'intelligence artificielle permettant aux ordinateurs de simuler une intelligence en apprenant par l'environnement qui les entoure. Cette technologie englobe différentes méthodes permettant de créer des modèles à partir de données. Pour cela il est nécessaire de programmer la machine pour lui apprendre à reconnaître et reproduire, à partir de données en se basant sur des statistiques, sur la reconnaissance de patterns et sur les analyses prédictives.

Pour que l'intelligence apprenne à réaliser une tâche, il est nécessaire de fournir une grande quantité de données à l'algorithme, en fonction de la complexité de la tâche demandée.

2. Deep learning

Le deep learning appelé apprentissage profond est un sous-ensemble du machine learning dont les algorithmes utilisent une architecture à base de plusieurs couches d'unités de traitement non linéaires capable d'extraction et de transformation. Chacune des couches successives utilise la sortie de la couche précédente comme entrée des données. Cette architecture imite celle du cerveau humain, basée sur des réseaux de neurones communiquant via les synapses à travers les différentes couches du cerveau. Les algorithmes du deep learning apprennent de multiples niveaux de représentation qui correspondent à différents niveaux d'abstraction, ces niveaux forment une hiérarchie des concepts [6]. Un exemple d'application du deep learning est la conception des réseaux de neurones à convolution.

Les réseaux deviennent de plus en plus performants à mesure qu'ils reçoivent des données car ils peuvent être plus profonds et plus complexes.

3. Apprentissages

Il existe différents types d'apprentissage [7] :

a. Apprentissage supervisé

Un utilisateur guide la machine en lui fournissant une grande quantité d'exemple qui aura été labélisé au préalable. Cette étape de labélisation, indispensable, permet d'associer à une entrée, une classe souhaitée.

Le but d'un algorithme d'apprentissage supervisé est d'utiliser les données labélisées pour produire un modèle qui apprend à généraliser, et prédire les étiquettes/classes de nouvelle donnée jamais vu.

b. Apprentissage non-supervisé

Appliqué en particulier aux problèmes de clusterisation, procédé auquel on souhaite partitionner et classer des éléments hétérogènes dans des sous-groupes qui seraient lié par des caractéristiques communes. La machine va elle-même déterminer les traits en commun entre les données, sans intervention extérieure.

L'apprentissage supervisé est utilisé pour comprendre, classer et explorer des données dont le nombre de classes est inconnu ou dont le jeu de données est non labélisé.

c. Apprentissage semi-supervisé

Dans ce type d'apprentissage, le jeu de données (dataset) contient à la fois des données labélisées et non-labélisées. En général, la quantité de données non-labélisées est supérieure à la quantité de données labélisées. Le but de l'apprentissage semi-supervisé est le même que pour l'apprentissage supervisé.

L'utilisation d'exemples non labélisés pourrait aider l'algorithme à produire un meilleur modèle.

d. Apprentissage par renforcement

La machine « vit » dans un environnement et est capable de percevoir l'état de cet environnement via un agent. La machine peut exécuter des actions à chaque état. Ces différentes actions amènent différentes récompenses et peuvent bouger la machine dans un nouvel état de l'environnement. Le but de l'apprentissage par renforcement est d'apprendre à l'algorithme une politique.

Une politique est une fonction qui prend les données d'un état en entrée et en sort une action optimale à exécuter dans cet état. Cette action est optimale si elle maximise la récompense attendue moyenne. Le but de ce système étant d'amasser le maximum récompense possible, la machine pourra faire la différence entre les bonnes et mauvaises actions et ainsi favoriser à terme les bonnes actions.

L'apprentissage par renforcement essaye de reproduire le mécanisme naturel d'acquisition des connaissances, c'est-à-dire :

- Observer les effets de ses actions
- Analyser la qualité de ses actions à partir des observations faites
- Mettre en place des mesures correctives afin d'améliorer les prochaines actions
- Observer les effets de ses nouvelles actions

4. Réseau de neurones à convolution

Les réseaux de neurones à convolution, un type d'architecture issue des principes du deep learning, fonctionnent sur le modèle du cerveau humain et plus particulièrement du système visuel.

Un réseau de neurones à convolution est organisé avec différentes épaisseurs (« layers » en anglais) dont certaines spécifiques vont appliquer un filtre sur les images afin d'identifier des patterns et des éléments spécifiques (figure 1).

Les premières épaisseurs détectent des formes simples, les dernières épaisseurs vont-elles repérer les détails plus subtils et les organiser en éléments plus complexes.

Dans le cadre d'un apprentissage supervisé, le réseau va apprendre durant l'entraînement, se tromper en prédisant une valeur différente de la valeur de référence qui est-elle donnée par le superviseur humain.

Cet écart entre la prédiction et la référence est défini par la fonction de coût, appelée aussi fonction d'objectif ou encore de perte ou en anglais loss function. Le réseau va alors s'auto ajuster via une étape de rétro-propagation du gradient, on parle d'ajustage des poids. Cet algorithme de descente du gradient permet de minimiser la loss.

Cette notion de correction par rétro-propagation s'inspire elle aussi de la biologie par la rétro-propagation neuronale.

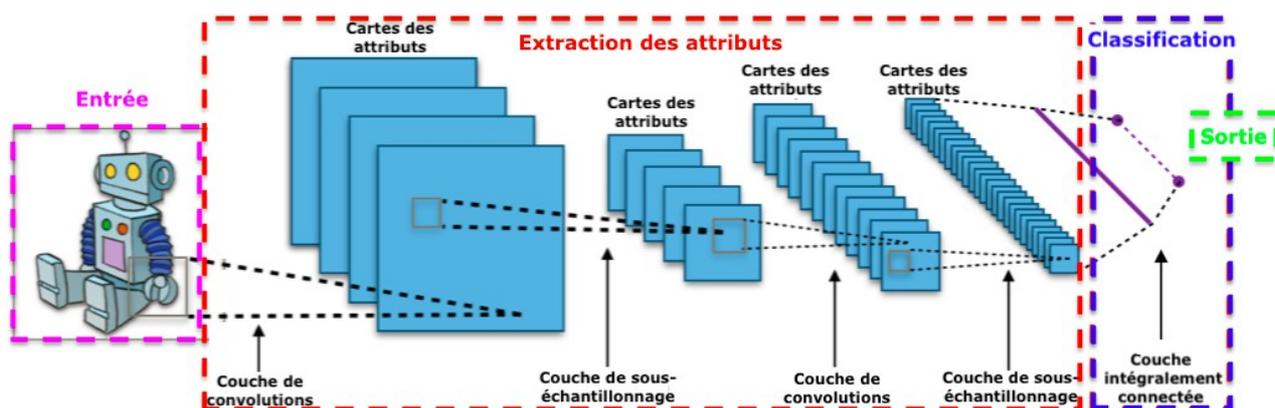


Figure 1: Schéma simplifié d'un réseau de neurones à convolution

a. Diminution de la fonction de coût

Le réseau va apprendre petit à petit, à partir de fractions de l'ensemble des données, fractions définies sous le terme de mini-batch ou mini-lot. Une itération correspond à l'apprentissage basé sur un mini-batch.

Lorsque le réseau a vu toutes les données dédiées à son entraînement, soit l'intégralité des mini-batches, et a réalisé la rétro-propagation, il est alors dit qu'une epoch est complétée. Lors d'un apprentissage, plusieurs epoch sont complétées.

A chaque itération et à chaque fin d'epoch, la fonction loss est calculée et les poids sont modifiés en fonction. L'apprentissage est mené jusqu'à obtenir une fonction loss qui reste stable, ne diminuant peu ou pas malgré un nombre d'epoch croissant.

Le réseau va s'entraîner sur un jeu de données appelé jeu d'entraînement ou training set avant de tester son modèle de prédiction sur un deuxième jeu de données appelé jeu de validation ou validation set. Ainsi il est alors possible de calculer deux fonctions de loss, l'une pour chaque jeu de données et voir leur évolution. Le but étant d'avoir une fonction loss la plus faible possible (Figure 2).

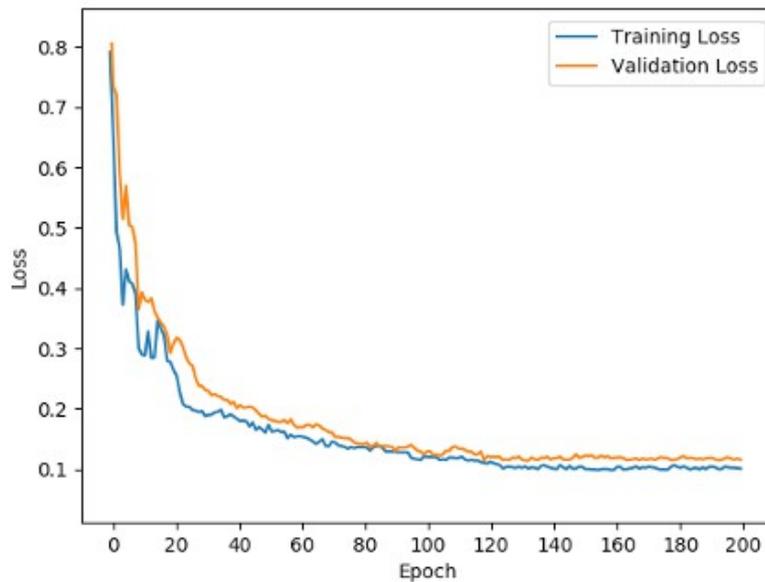


Figure 2: Exemple de fonctions loss en fonction du nombre d'epoch

b. Sur et sous-apprentissage

On souhaite avoir un réseau qui puisse effectuer des prédictions sur de nouvelles données. Selon la façon dont est entraîné le modèle, deux problèmes peuvent se présenter (Figure 3) :

b.1. Sur-apprentissage

Cela représente un modèle qui a appris par cœur ses données d'entraînement, qui fonctionne donc bien sur le jeu d'entraînement mais pas sur celui de validation. Il effectue alors de mauvaises prédictions sur de nouvelles données, car elles ne sont pas exactement les mêmes que celle du jeu d'entraînement. Pour y remédier, il faut améliorer la flexibilité du modèle.

b.2. Sous-apprentissage

Ce cas-ci représente un modèle qui n'arrive pas à déduire des informations du jeu de données. Il n'apprend donc pas assez et réalise de mauvaises prédictions sur le jeu d'entraînement. Il faut donc complexifier le réseau, car il n'arrive pas à comprendre la relation entre les données d'entrées et leur label.

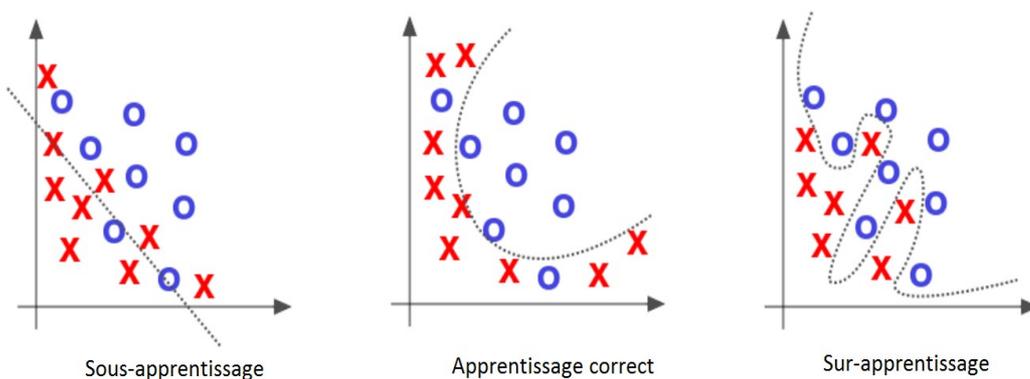


Figure 3: Schéma de sous et sur-apprentissage

Dans le cas où la précision du réseau n'est ni bonne sur le jeu d'entraînement, ni sur celui de validation, c'est que le réseau n'a pas eu assez de temps pour apprendre des données. Il faut donc augmenter le nombre d'itération, ou augmenter la taille du jeu de données.

c. Vitesse d'apprentissage

La modification des poids peut être plus ou moins importante, elle est définie par la vitesse d'apprentissage ou learning rate. Un learning rate élevé risque de développer un réseau peu optimisé car les corrections seront trop importantes pour obtenir des améliorations tandis qu'un learning rate trop faible nécessitera beaucoup plus de temps d'apprentissage, les modifications étant très faibles, avec le risque de s'arrêter avant d'avoir un réseau optimisé.

Le but des corrections du réseau est d'atteindre le minimum local de la loss en fonction des paramètres du réseau. La figure 4 propose une vision simplifiée des répercussions qu'entraîne la modification de la vitesse d'apprentissage.

La vitesse d'apprentissage du réseau est une variable modifiable, son optimisation permet d'avoir des meilleures prédictions en demandant moins d'apprentissage. Il s'agit d'un des hyper-paramètres les plus importants.

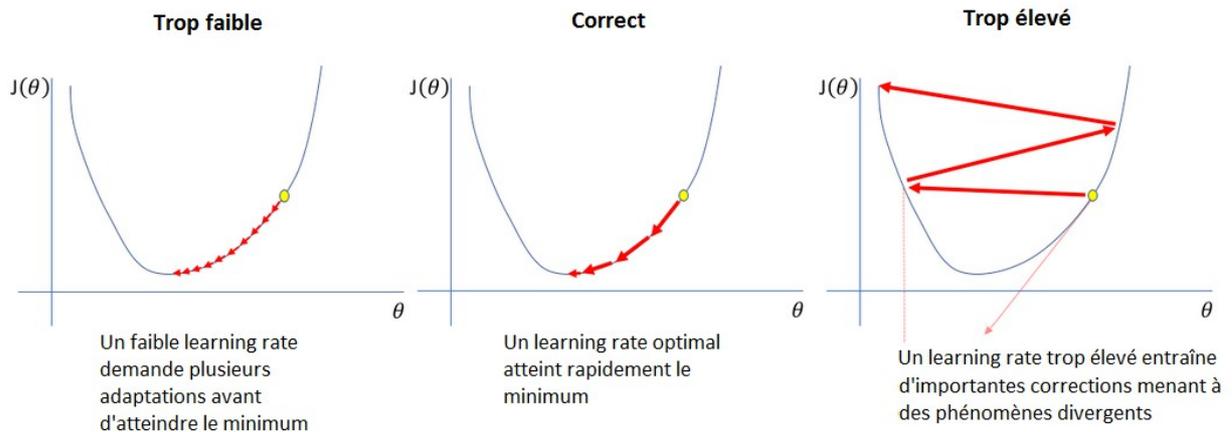


Figure 4: Schéma simplifié des différents learning rate

5. Transformations d'une image

a. Classification

La classification d'une image consiste à attribuer une classe à une image (Illustration 3).



Illustration 3: Exemple de classification

b. Détection

La détection d'objet se superpose à la simple classification en ajoutant la localisation de l'objet. Une classe associée avec une position est attribuée à une partie de l'image. Cette partie est souvent définie par des rectangles appelés bounding box (Illustration 4).

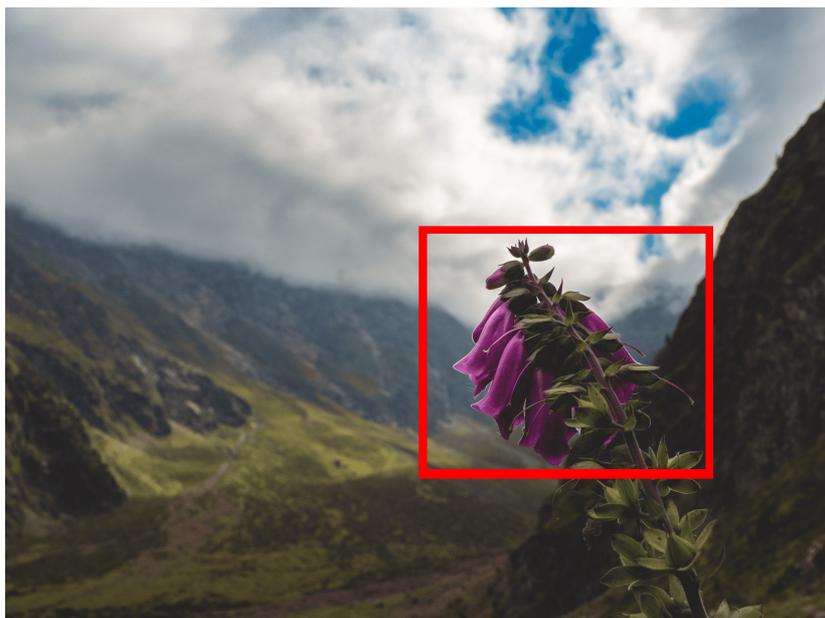


Illustration 4: Exemple de détection d'objet

c. Segmentation

La segmentation est un processus permettant de classer chaque pixel d'une image en un label ou classe.

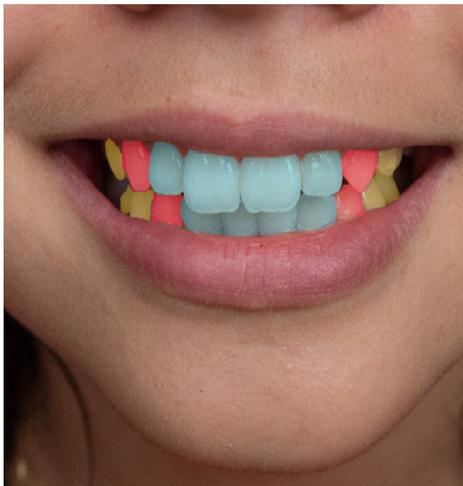
Elle peut être sémantique ou d'instance.

La segmentation sémantique ne peut faire de différence entre deux instances d'une même classe, à l'inverse la segmentation d'instance est capable d'attribuer une classe unique pour chaque instance d'un même objet au sein d'une même image.

Sur l'illustration 5 nous pouvons voir les différences entre la segmentation sémantique et d'instance. Dans le premier cas, la segmentation sémantique permet de classer les dents selon leur nature, incisive/canine/prémolaire mais ne permet pas la distinction entre les différentes incisives par exemple. Toutes les dents de la même nature sont segmentées dans une seule classe.

La segmentation d'instance permet elle aussi de classer les dents selon leur nature en les entourant mais elle permet au sein d'un même groupe, de différencier chacun des composants de ce groupe. Ainsi pour la classe des incisives, la segmentation d'instance va différencier chacune des incisives composant ce groupe et leur attribuer une couleur différente.

SEGMENTATION D'OBJET



INCISIVES - CANINES - PREMOLAIRES

SEULEMENT DES PIXELS,
PAS D'OBJET



INCISIVE - INCISIVE - INCISIVE - INCISIVE
CANINE - CANINE
PREMOLAIRE - PREMOLAIRE

MULTIPLE OBJET

Illustration 5: Exemple de segmentation d'objets, sémantique à gauche, d'instance à droite

C. L'intelligence artificielle en odontologie

Les progrès dans le domaine de l'intelligence artificielle ont permis l'émergence des techniques de machine learning et plus précisément de deep learning. Ces champs d'application de l'intelligence artificielle ont permis d'entraîner les algorithmes pour réussir à atteindre des hauts niveaux de compétences. Cette avancée technologique se retrouve dans le domaine de la santé, permettant une meilleure prise en charge du patient via par exemple une diminution du risque d'erreur lors du diagnostic et lors de la pratique quotidienne.

Une des spécialités médicales où le domaine de l'intelligence artificielle s'est considérablement développé est le domaine de la radiologie. En effet, avec le passage au numérique de tous les clichés radiographiques, une très grande quantité de données sont disponibles pour permettre d'entraîner les . De plus, l'analyse des clichés radiographiques sert à repérer et mettre en avant un aspect visuel physiologique ou pathologique au sein de l'image. Cette fonction de détection est un sujet de recherche et développement dans d'autres secteurs et cela depuis déjà des années avec notamment la reconnaissance faciale ou la reconnaissance de plaque d'immatriculation. Ainsi l'application au domaine de la radiographie médicale a pu bénéficier des recherches déjà existantes dans d'autres domaines.

L'analyse des clichés radiographiques par intelligence artificielle en odontologie est un sujet de recherche en développement depuis 5 ans environ. Ce domaine d'application repose sur les principes du deep learning et l'utilisation des réseaux de neurones est croissante. On retrouve notamment l'utilisation des réseaux de neurones à convolution avec comme application :

- la détection de lésions carieuses [8]
- la segmentation du foramen mentonnier [9]
- la segmentation de la troisième molaire [10]
- la segmentation des différents tissus de la dent [11]
- la détection de la perte du niveau osseux sur une radiographie panoramique [12]

Ces applications utilisant comme données initiales des radiographies intrabuccales ou des panoramiques dentaires.

Il est également possible d'entraîner un réseau sur des données issues d'une caméra par transillumination [13] (Illustration 6).

Ces applications encore au stade de la recherche veulent à terme permettre le développement d'un outil d'aide à la détection ou au diagnostic de lésions visibles à l'examen radiographique comme la détection de lésions carieuses, de perte de niveaux osseux, de lésion endodontique para-apicale, de kystes...

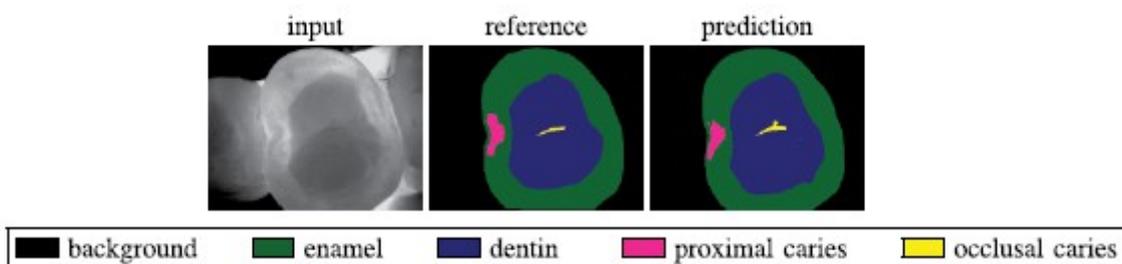


Illustration 6: Application d'un réseau de neurones à convolution pour la segmentation d'une dent à partir d'une image issue d'une caméra par transillumination [13]

Input : image d'origine

Reference : segmentation faite par les experts

Prediction : segmentation prédite par le réseau de neurones à convolution

D. Introduction à l'étude

L'étude que nous avons menée porte sur l'utilisation d'un réseau de neurones à convolution afin de segmenter une ou plusieurs lésions carieuses à partir d'une radiographie intra-buccale.

La détection des lésions carieuses est un élément important lors de l'examen afin de pouvoir détecter et prévenir la carie dentaire, qu'elle soit à un stade précoce ou avancé. Les lésions carieuses sont visibles à la radiographie qui est un examen fréquent, permettant de visualiser les zones interdentaires et l'intérieur de la dent par coupe.

La radiographie intra-buccale est un examen complémentaire ne permettant pas de poser un diagnostic définitif mais pouvant aider à la visualisation de l'étendue de la lésion.

La radiographie panoramique est souvent réalisée en tant qu'examen complémentaire dans le cadre d'un bilan bucco-dentaire global. Cet examen complémentaire peut mettre en évidence des lésions carieuses qui n'auraient pas été constatées cliniquement.

L'utilisation de l'intelligence artificielle comme aide au diagnostic en dentaire se positionne comme une aide indiquant au chirurgien-dentiste la localisation de possibles lésions. Pour cela, l'analyse de la radiographie panoramique par IA semble être l'indication idéale de l'utilisation des réseaux de neurones à convolution.

Dans le cadre de notre étude, notre choix s'est porté sur l'analyse de radiographies intra-buccales car le temps nécessaire afin d'obtenir et de segmenter un nombre important de panoramiques dentaires aurait été trop important et difficilement réalisable dans le cadre d'une thèse d'exercice en chirurgie-dentaire.

Le choix d'un réseau de neurones à convolution afin de réaliser cette tâche s'est basé sur la littérature récente qui montre une grande efficacité des réseaux de neurones à convolution dans la détection et la localisation d'objet par une intelligence artificielle [14]. L'utilisation de ces derniers dans les recherches en odontologie est encore peu fréquente avec quelques études publiées depuis les dernières années [15].

Le but de cette étude était d'évaluer la validité de notre réseau de neurones à convolution dans la segmentation des lésions carieuses à partir de radiographies intra-buccales. Pour cela, nous avons mesuré différents paramètres en sortie de réseaux que nous avons comparés à d'autres études.

II. Matériel et Méthodes

A. Collecte des données

Un total de 10000 radios intrabuccales a été récupéré depuis les données du service d'odontologie de Pellegrin du CHU de Bordeaux.

Sur ces 10000 radios, 1375 ont été sélectionnées suivant les critères suivant :

Critère d'inclusion :

- Radiographie avec une ou plusieurs dents visibles, cliniquement utilisable dans la détection de lésion carieuse : intégralité de la couronne visible jusqu'à la limite osseuse pour la dent radio-centrée avec superposition inférieure à $\frac{1}{4}$ de la portion coronaire
- Radiographie en denture permanente, lactéale et mixte
- Radiographie avec implant seul

Critères de non-inclusion :

- Radiographie non utilisable cliniquement : $\frac{3}{4}$ de la dent non visible, flou, mauvaise exposition, superposition des dents supérieures à $\frac{1}{4}$ de la partie coronaire
- Radiographie prise lors d'un traitement endodontique
- Présence de crampon
- Défaut du capteur visible à la radiographie gênant l'interprétation : rayure, plis

Les radios ont été prises dans le service d'odontologie de Pellegrin et développées avec le logiciel DBSWIN Dürr Dental (Illustration 7).

Des radios avec des implants ou des brackets en place ont été incluses dans le data set afin que le modèle puisse s'entraîner à voir ces situations et éviter qu'il ne segmente une carie sur l'implant en lui-même.



Illustration 7: Exemple de radiographies incluses dans l'étude

B. Répartition des données

1100 (75%) radios ont été classées dans le data set qui servira à l'apprentissage du réseau de neurones et 275 (25%) radios dans le jeu de données de test (test set) afin d'évaluer l'algorithme en mesurant les métriques. Les métriques sont des indicateurs statistiques mesurables et quantifiables. Les radiographies ont été réparties de manière aléatoire tout en respectant la proportion de chaque sous-groupe lié à la nature des dents radiographiées.

1. Data set

Les radios sélectionnées ont été classifiées en fonction des dents affichées, sur les 1100 radios il y a :

- 160 radiographies du groupe incisivo-canin (14%)
- 151 radiographies du groupe canine-prémolaires (14%)
- 725 radiographies du groupe prémolo-molaire (66%)
- 6 radiographies d'implant seul (0,5%)
- 12 radiographies avec des brackets, localisation non-différenciée (1%)
- 46 radiographies de dents lactéales, localisation non-différenciée (4%)

Les dents ont été classées indifféremment entre maxillaire supérieur et inférieur.

Nous pouvons noter un plus grand nombre de radiographies comprenant des molaires ou des prémolaires, cela peut s'expliquer par le fait que ces dents sont plus souvent prises en radiographies afin de détecter des lésions carieuses ou d'en voir l'étendue.

Parmi les groupes, on retrouve 50% de dents cariées et 50% de dents saines (Tableau 1).

Groupe	Nombre de dents non-cariées (%)	Nombre de dents cariées (%)	Total
Incisivo-canin (IC)	73 (45%)	87 (55%)	160
Canine-prémolaire (CP)	87 (58%)	64 (42%)	151
Prémolo-molaire (PM)	360 (50%)	365 (50%)	725
Implant seul (I)	6 (100%)	0 (0%)	6
Dents avec brackets (O)	12 (100%)	0 (0%)	12
Dents lactéales (E)	7 (15%)	39 (85%)	46
Total	545 (50%)	555 (50%)	1100

Tableau 1: Composition du data set

Sur les 1100 radios de ce data set, 880 soit 80% ont été attribuées de manière aléatoire à l'entraînement du réseau et 220 soit 20% à la validation du modèle.

2. Test set

Les radios incluses dans ce jeu de données n'ont jamais été analysées par le modèle afin d'éviter de biaiser les résultats avec des radios déjà utilisées lors de l'entraînement ou de la validation.

Le test set est composé de 275 radiographies distribuées selon les groupes :

- 40 radiographies du groupe incisivo-canin (15%)
- 37 radiographies du groupe canine-prémolaires (13%)
- 180 radiographies du groupe prémolo-molaire (65%)
- 3 radiographies d'implant seul (1%)
- 3 radiographies avec des brackets, localisation non-différenciée (1%)
- 12 radiographies de dents lactéales, localisation non-différenciée (4%)

Les dents ont été classées indifféremment entre maxillaire supérieur et inférieur.

Parmi les groupes, on retrouve 46% de dents cariées et 54% de dents saines (Tableau 2).

Groupe	Nombre de dents non-cariées (%)	Nombre de dents cariées (%)	Total
Incisivo-canin (IC)	27 (68%)	13 (32%)	40
Canine-prémolaire (CP)	27 (73%)	10 (27%)	37
Prémolo-molaire (PM)	87 (48%)	93 (52%)	180
Implant seul (I)	3 (100%)	0 (0%)	3
Dents avec brackets (O)	3 (100%)	0 (0%)	3
Dents lactéales (E)	1 (8%)	11 (92%)	12
Total	148 (54%)	127 (46%)	275

Tableau 2: Composition du test set

C. Segmentation des lésions carieuses

Les radios du data set et du test set ont été analysées par moi-même, Van-Hoan Nguyen, étudiant en 6^{ème} année d'odontologie à l'Université de Bordeaux à l'aide du logiciel SuperAnnotate 1.0.0. Sur ce logiciel, les caries ont été segmentées, les zones carieuses ont été entourées selon examen de la radiologie seule (Illustration 8).

Les paramètres de luminosité et de contraste des radios ont pu être modifiés directement dans le logiciel afin de mieux mettre en évidence les lésions carieuses.

La segmentation sur le logiciel SuperAnnotate a permis l'obtention des coordonnées de la surface cariée correspondant à chaque radiographie.

La segmentation des zones carieuses a été guidée par les références bibliographiques afin de sélectionner au mieux les zones cariées tout en évitant les artefacts [16].



Illustration 8: Exemple de segmentation d'une carie

La segmentation manuelle réalisée par l'opérateur humain donne une référence qui est nécessaire pour l'entraînement et l'évaluation du modèle mais ne représente pas forcément la réalité clinique. En effet, aucune confirmation clinique de la présence ou de l'absence de lésion carieuse ainsi qu'aucune analyse clinique de l'étendue de la lésion n'a pu être réalisée. La segmentation des lésions carieuses s'est basée sur l'examen radiographique uniquement, en s'aidant de références bibliographiques.

L'analyse histologique des tissus dentaires est le gold standard pour évaluer l'étendue de la lésion carieuse mais pour notre data set, cela est difficilement réalisable compte tenu du nombre de radiographies et cela ne permettrait pas d'avoir une segmentation des lésions carieuses correspondant à la radiographie initiale.

La concordance de diagnostic entre plusieurs praticiens dans la détection et la segmentation de lésions carieuses à partir de radiographies intrabuccales est acceptable pour une utilisation clinique, malgré les légères différences inter et intra-examineur [17]. Dans le cadre de cette thèse, la participation de plusieurs examinateurs au lieu d'un seul aurait été préférable mais cela n'a pas été possible, compte tenu en partie du temps nécessaire à l'annotation des 1375 radiographies.

D. Programmation du réseau et pré processing

Le réseau de neurones à convolution a été programmé en langage Python avec les bibliothèques Keras et Tensorflow. L'architecture du réseau est basée sur U-Net++ (2018), elle a été ensuite personnalisée pour les besoins de notre étude. Le réseau U-Net++ étant adapté à la segmentation d'images médicales [18]. L'intégralité du code source est disponible dans le lien en annexe.

Le réseau a été pré-entraîné avec la banque de données Imagenet qui a permis de paramétrer les poids du réseau sur cette base.

La dernière fonction d'activation de la dernière couche du réseau donne une valeur comprise entre 0 et 1 pour chaque pixel car cette fonction est basée sur une fonction sigmoïde. Cette valeur correspond à la probabilité qu'un pixel soit classé dans la catégorie « carie » selon la prédiction du modèle.

La valeur seuil a été paramétrée à 0,95 compte tenu du décalage du nombre de pixel entre carie et sain. Pour toute valeur comprise entre 0 et 0,94, le modèle classifiera le pixel en sain et de 0,95 à 1 en tant que carie.

A partir des coordonnées de la segmentation réalisée sur le logiciel SuperAnnotate, un masque de la zone segmentée a été généré pour chaque radiographie (Illustration 9). En cas d'absence de carie segmentée, le masque se retrouve vide.

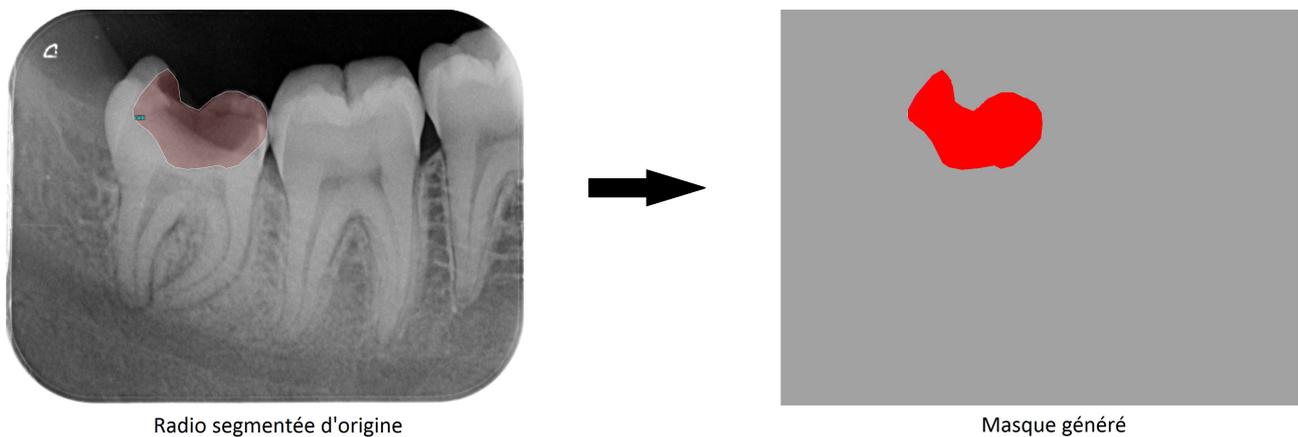


Illustration 9: Génération du masque à partir d'une radiographie segmentée

E. Augmentation des données

Nous avons utilisé le procédé d'augmentation des données ou data augmentation en anglais afin de fournir plus de données au réseau pour son apprentissage. Pour cela, diverses opérations de déformation de l'image ont été appliquées (rotation, miroir...) aux images et aux masques correspondants (Illustration 10).

Ces opérations ont été appliquées en particulier aux radiographies avec des caries car le data set est déséquilibré au niveau de la répartition : zone cariée-zone saine. En effet, même si le nombre de radiographie avec ou sans carie est proche (545 pour 555), la zone segmentée comme carie est largement inférieure au background.

Après application de l'augmentation d'image, le data set est composé de 11090 radiographies avec toujours une proportion de 80% attribuée à l'apprentissage et 20% à la validation.

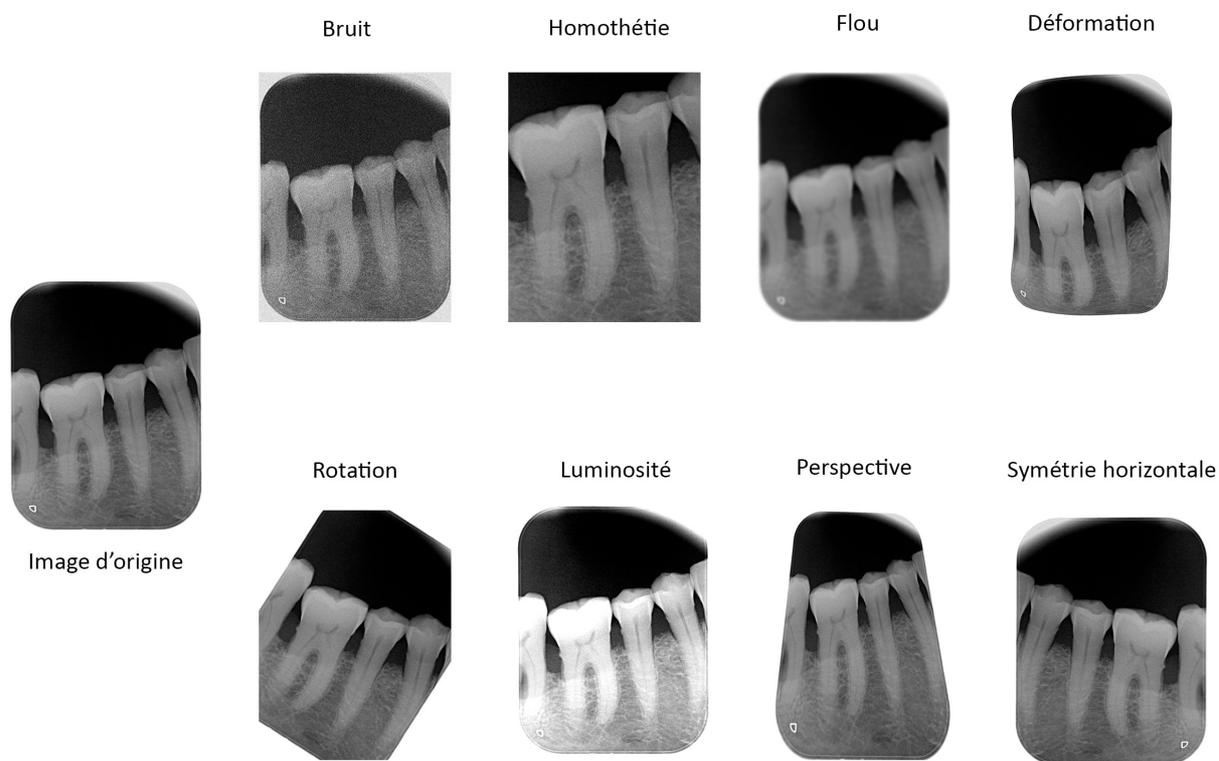


Illustration 10: Exemple des modifications d'une image

F. Analyse Statistique

L'intégralité des résultats obtenus ont été mesurés directement à la sortie du modèle en implémentant dans le code les fonctions permettant de récupérer ces données. Les fonctions implémentées sont issues de la bibliothèque open source scikit-learn.

1. Classification des pixels

A la sortie du modèle, nous obtenons une radiographie associée à deux masques, l'un donné par l'examinateur qui sert de référence et l'autre prédit par le modèle. Pour chaque pixel du masque prédit, il est alors possible de le classer en tant que vrai ou faux positif ou négatif par rapport au masque de référence (Figure 5).

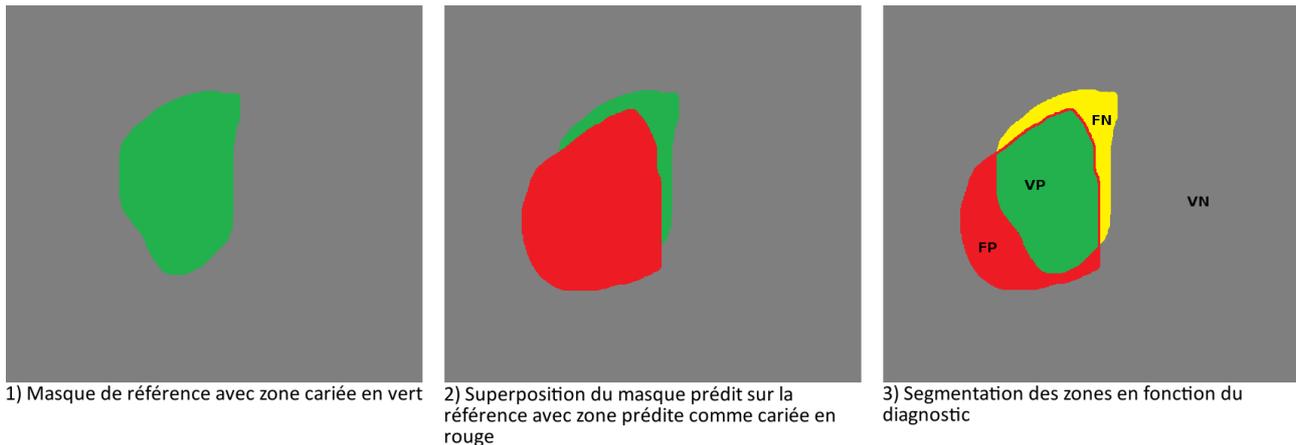


Figure 5: Classification des pixels en fonction du diagnostic

2. Matrice de confusion

La matrice de confusion a été calculée pour chaque sous-groupe ainsi que pour le total des radiographies du test set. La matrice de confusion donne le nombre de vrai positif, faux positif, vrai négatif et faux négatif (Tableau 3).

		Prédiction	
		Pixel non-carié	Pixel carié
Référence	Pixel non-carié	Vrai Négatif	Faux Positif
	Pixel carié	Faux Négatif	Vrai Positif

Tableau 3: Exemple de matrice de confusion

3. Sensibilité, spécificité, précision

A partir des résultats obtenus par la matrice de confusion, nous avons calculé pour chaque sous-groupe et pour le total les valeurs de sensibilité, spécificité et précision. Ces mesures sont définies sous le terme de métriques.

La sensibilité est la probabilité que le test soit positif si le caractère recherché est bien présent. Dans notre cas, la probabilité que le pixel soit prédit comme carié si la référence le définit comme carié. Elle est calculée par la formule :

$$\text{Sensibilité} = \frac{\text{Vrais Positifs}}{\text{Vrais Positifs} + \text{Faux Négatifs}}$$

La spécificité est la probabilité que le test soit négatif si le caractère recherché est bien absent. Dans notre cas, la probabilité que le pixel soit prédit comme non-carié si la référence le définit comme non-carié. Elle est calculée par la formule :

$$\text{Spécificité} = \frac{\text{Vrais Négatifs}}{\text{Vrais Négatifs} + \text{Faux Positifs}}$$

La précision est la probabilité que la condition recherchée soit bien présente lorsque le test est positif. Pour notre cas, la probabilité que le pixel soit carié lorsque le modèle le prédit en tant que carie. La précision est également appelée valeur prédictive positive et est calculée par la formule :

$$\text{Précision} = \frac{\text{Vrais Positifs}}{\text{Vrais Positifs} + \text{Faux Positifs}}$$

4. Coefficient de Dice

Pour évaluer notre modèle, nous avons choisis le coefficient de Dice appelé également indice de Sørensen-Dice ou score F1. Cette métrique est un indicateur de concordance entre la zone segmentée prédite par le modèle et la zone de référence, donnée par l'opérateur humain.

Cet indice est obtenu par la formule :

$$\text{Coefficient de Dice} = 2 \frac{(\text{Précision} * \text{Sensibilité})}{(\text{Précision} + \text{Sensibilité})}$$

5. Fonction d'efficacité du récepteur et aire sous la courbe

La fonction d'efficacité du récepteur, appelé courbe ROC (Receiver Operating Characteristic) a été mesurée dans la classification des pixels en tant que carie ou non.

La mesure ROC est représentée sous la forme d'une courbe donnant le taux de vrais positifs en fonction du taux de faux positifs. Elle permet d'évaluer la performance du modèle dans la classification binaire des pixels : carie ou sain.

L'aire sous la courbe ROC a été obtenue en calculant l'intégrale de la courbe ROC. Cette valeur comprise entre 0 et 1 est appelée aire sous la courbe ou AUC (Area Under Curve).

Une valeur d'AUC égale à 1 signifie que le modèle ne se trompera jamais dans la classification des pixels en carie ou sain tandis qu'une valeur égale à 0 signifie qu'il se trompera toujours.

Le choix de ces métriques a été fait selon la littérature récente afin de pouvoir comparer les résultats de notre réseau face à des études similaires [19].

III. Résultats

A. Fonction de coût

La fonction de coût a été récupérée lors des entraînements et est décrite dans la figure 6.

Nous pouvons constater une diminution progressive de la fonction de coût du jeu de validation (val) avec une nette diminution un peu avant la 10ème epoch suivie d'un plateau où la fonction de coût ne varie que légèrement sans diminution notable.

Le schéma général de cette fonction permet d'écarter les phénomènes de sur et sous-apprentissage.

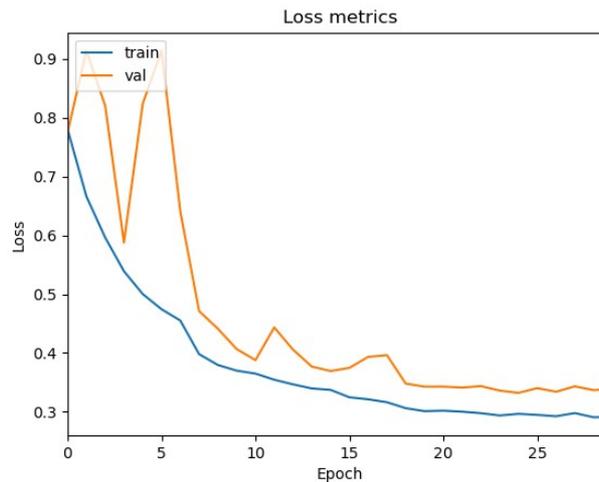


Figure 6: Fonction de coût

B. Métriques

A partir des résultats obtenus par le réseau dans la segmentation du test set, nous avons calculé les métriques choisies (Tableau 3).

Métrique		Précision	Sensibilité	Spécificité	Dice	AUC
Test Set	Incisivo-canin	0,99	0,4	0,99	0,57	0,7
	Canine-prémolaire	0,99	0,36	0,99	0,53	0,68
	Prémolo-molaire	0,99	0,46	0,99	0,63	0,73
	Dents lactéales	0,98	0,35	0,99	0,52	0,67
	Total	0,99	0,44	0,99	0,61	0,72

Tableau 4: Valeurs de précision, sensibilité, spécificité, indice de Dice et AUC pour la segmentation des lésions carieuses dans les différents groupes et le total

Nous avons réalisé ce tableau en excluant les groupes « Implant seul » et « Dents avec brackets » qui ne contenaient aucune lésion carieuse, donc aucun vrai positif possible empêchant le calcul de la sensibilité, précision et indice de Dice.

La spécificité du modèle sur ces groupes est respectivement de 1 et de 0,99.

C. Matrices de confusion

Les matrices de confusion ont été obtenues directement par le modèle et sont décrites dans la figure 8. La figure 7 donne un exemple d'interprétation des matrices de confusion.

Une matrice de confusion est donnée pour chaque groupe ainsi que pour le total. En abscisse se trouve les deux catégories prédites : « background » pour un pixel classé comme sain et « carry » pour un pixel classé comme carié. En ordonnée se trouve les deux mêmes catégories servant de référence, basée sur la segmentation de référence.

La valeur affichée à l'intérieur de la matrice correspond au pourcentage de pixel classé dans chaque catégorie par rapport à la catégorie référence.

Pour la matrice de confusion basée sur l'ensemble des données (« Confusion Matrix for TOTAL »), on note que sur les pixels classés comme sains par la référence, le modèle prédit plus de 99% de pixels sains (« background ») et moins de 0,1% de pixel carié (« carry »). Le modèle ne prédit donc qu'un très faible nombre de faux positifs.

Pour les pixels classés comme cariés par la référence, le modèle prédit 69 % de pixels comme sains et 31 % de pixels comme cariés. Le modèle prédit donc plus de faux négatifs que de vrais positifs de manière générale.

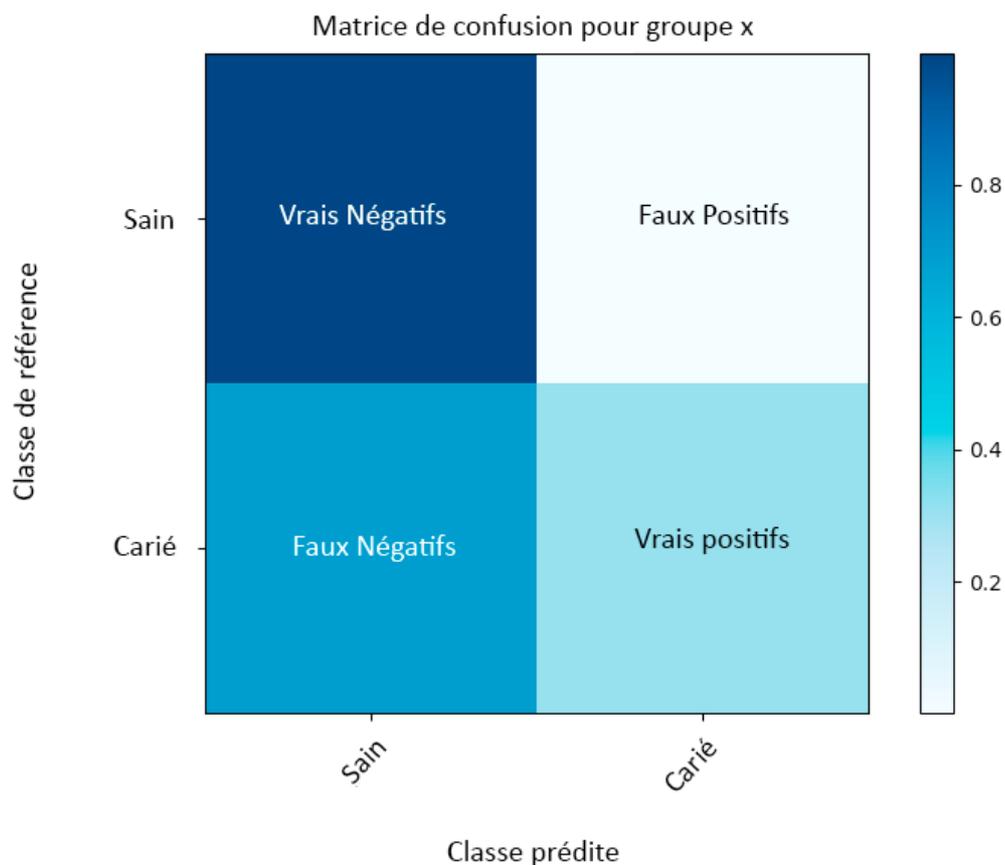


Figure 7: Exemple de matrice de confusion

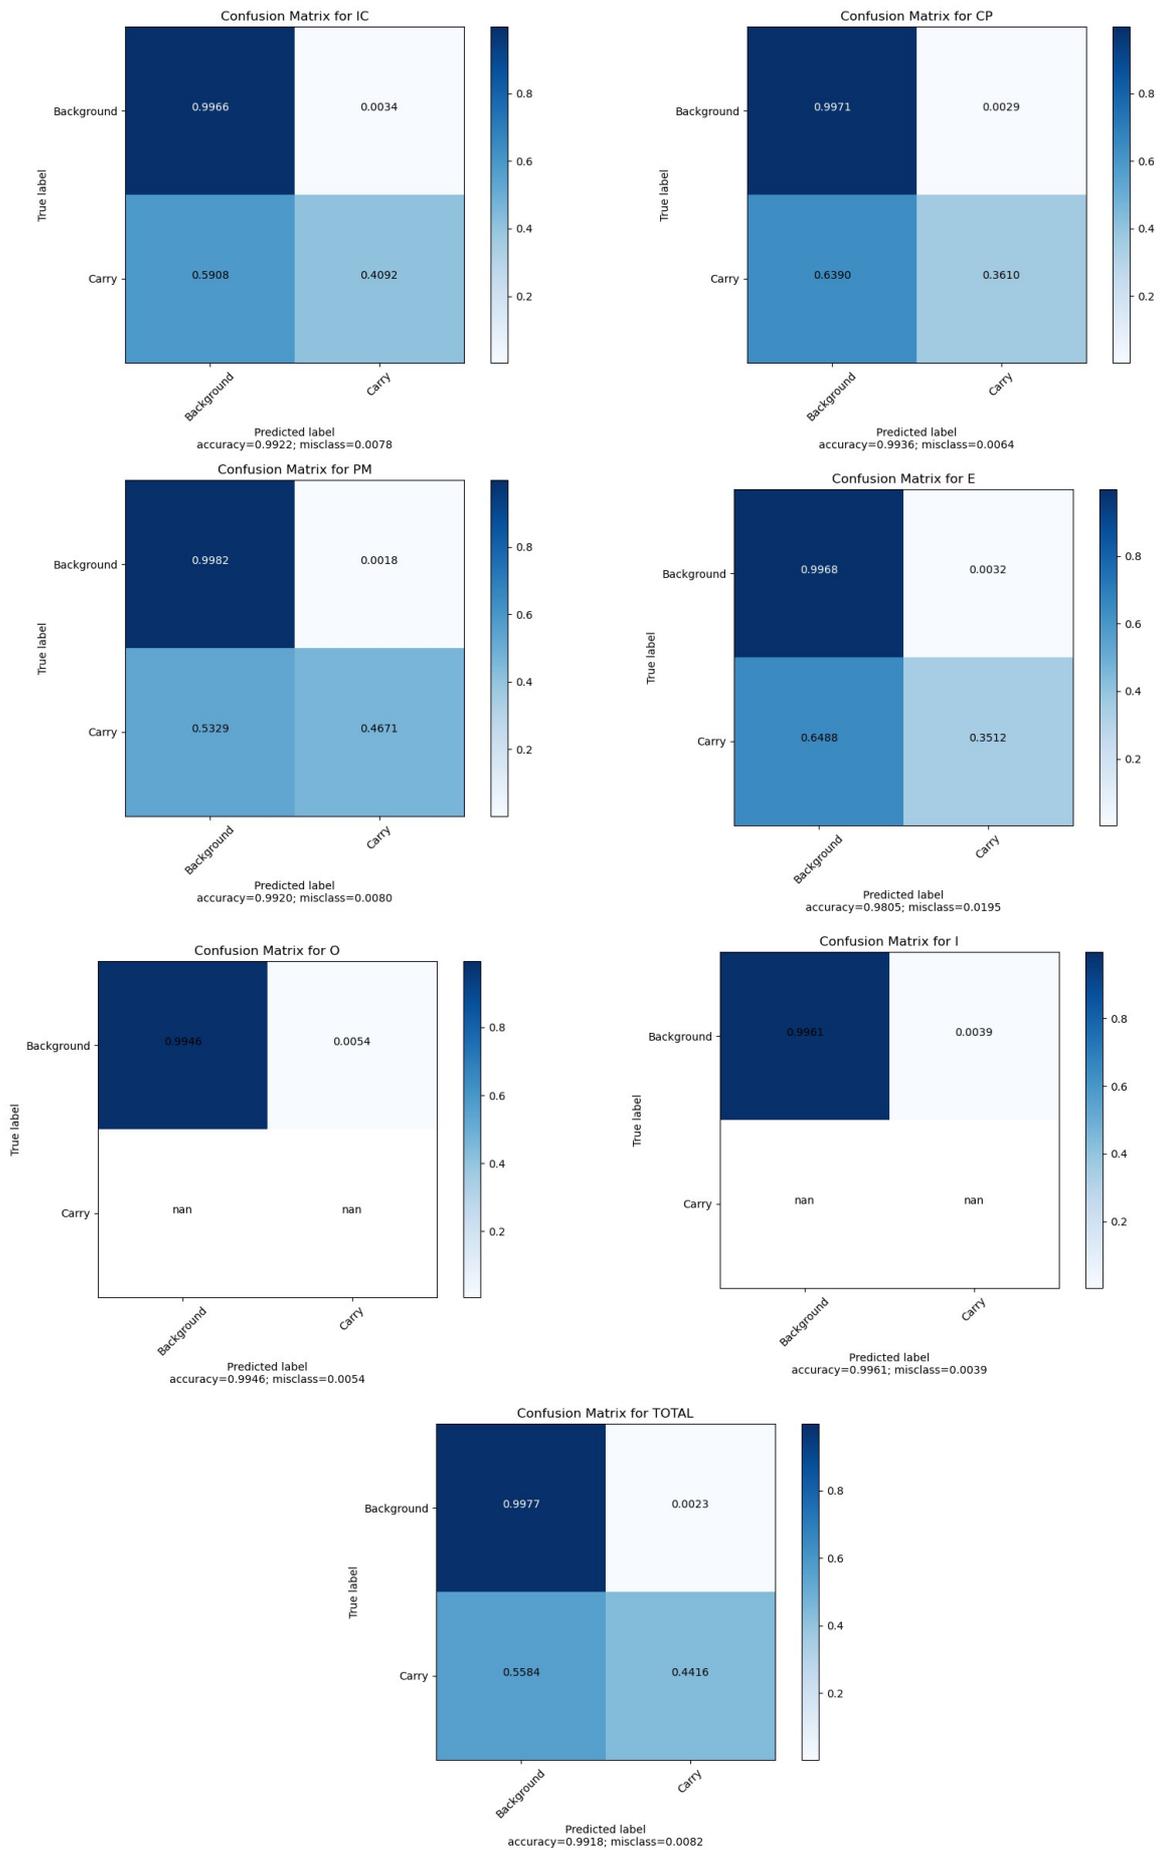


Figure 8: Matrice de confusion pour les différents groupes et le total

D. Fonctions d'efficacité du récepteur

Les fonctions d'efficacité du récepteur ont été calculées ainsi que l'aire sous la courbe («ROC curve area») dans la figure 9. La ligne en pointillés noirs représente une fonction d'efficacité du récepteur aléatoire.

Les fonctions n'ont pas pu être calculées pour les groupes « Implant seul » et « Dents avec brackets » car dans le jeu de données, aucune lésion carieuse n'était visible sur ces dents.

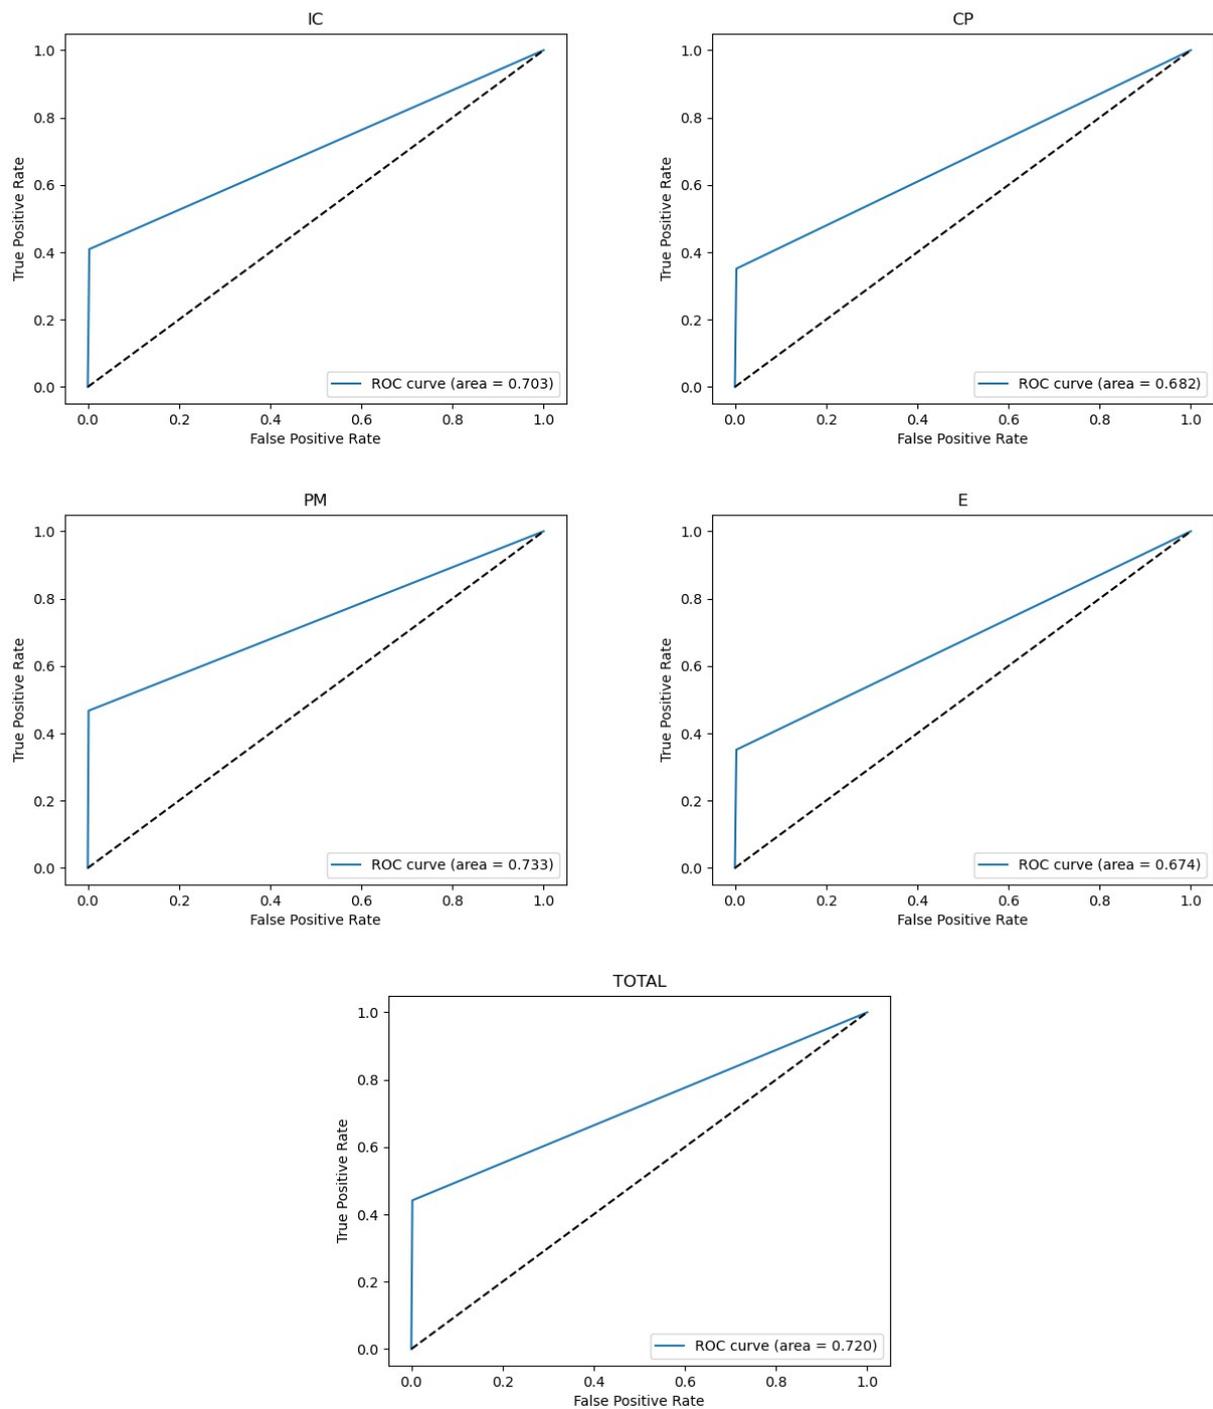


Figure 9: Fonction d'efficacité du récepteur et aire sous la courbe de différents groupes et du total

IV. Discussion

La détection et la segmentation des lésions carieuses est un aspect essentiel dans la prise en charge de la carie afin d'éviter son avancée et qu'elle ne mette en péril l'intégrité de la dent.

A. Analyse des résultats

Le modèle obtenu par apprentissage supervisé a réussi à produire des prédictions plausibles, en accord avec les données sur lequel il a été entraîné. Le réseau de neurones à convolution disposait de suffisamment de données pour éviter les phénomènes de sur ou sous-apprentissage.

Ces résultats ne permettent cependant pas une utilisation en clinique compte tenu des valeurs des métriques mesurées (Dice = 0,61 ; AUC = 0,71), traduisant trop d'erreurs dans le diagnostic des zones cariées. Ces erreurs sont principalement des erreurs de sous-diagnostic, avec une sensibilité égale à 0,44 tandis que la spécificité est de 0,99, traduisant une quasi-absence de faux négatifs.

Nous pouvons noter une différence entre les coefficients de Dice mesurés dans les groupes prémolaire et les groupes incisivo-canin et canine-prémolaire (groupe PM Dice=0,63 ; groupe IC Dice=0,57 ; groupe CP Dice=0,53) liée possiblement à l'écart important du nombre de radios dédiées à l'apprentissage (groupe PM n=725 ; groupe IC n=160 ; groupe CP n=151). Nous pouvons cependant penser que le modèle a réussi à identifier les lésions carieuses indépendamment de la nature de la dent.

Nous pouvons également noter de moins bons résultats du réseau sur le groupe des dents lactéales avec un Dice = 0,52 contre 0,61 pour le total. Cela peut être expliqué par la faible quantité de données de radios avec des dents lactéales dans le data set (n=46 soit 4% du total) qui n'ont pas permis un apprentissage correct de cette situation. Le cas des dents lactéales diffère en effet des dents définitives compte tenu de la morphologie différente de ces dents ainsi que la présence des dents définitives en dessous avec parfois une rhizalyse.

Notre modèle montre cependant des avancées en termes de résultats dans la segmentation des lésions carieuses à partir de radiographies intra-buccales par rapport aux précédentes études menées sur des radiographies dentaires.

Les résultats décrits dans le tableau 1 montrent une amélioration des métriques par rapport à l'étude menée par Ronneberger et al.[11], ainsi nous sommes passés d'un indice de Dice de 0,12 (test set 1) ou 0,13 (test set 2) à 0,61 pour notre étude pour la segmentation des caries.

Cette différence peut être expliquée par l'augmentation du nombre de données, de 39 radiographies rétro-coronaires dans l'étude de Ronnerberger et al. nous sommes passé à 1375 radiographies et l'architecture du réseau de neurones à convolution a évolué du modèle U-net à U-net++, une architecture plus récente.

Cette même étude montre les difficultés à segmenter correctement les lésions carieuses par rapport aux tissus sains de la dent, cela peut être expliqué par l'aspect très variable des lésions alors que les tissus naturels de la dent présentent le même aspect physiologique et donc une redondance possiblement plus facile à segmenter.

Notre étude montre également de moins bons résultats dans la segmentation des caries par rapport à un réseau programmé pour l'analyse de photos issues d'une caméra à transillumination [13]. Dans cette étude, l'AUC mesuré pour les lésions carieuses est de 0,85 pour les lésions proximales et de 0,83 pour les lésions occlusales contre 0,72 pour tout type de lésion dans notre étude.

Ce delta peut être lié à une meilleure optimisation du réseau de neurones, à un meilleur diagnostic des lésions servant de référence ou à une détection des lésions facilitées par les images de la caméra par rapport aux radiographies.

B. Limites de l'étude

Pour améliorer les métriques de notre réseau, il serait intéressant de lui fournir plus de données, c'est-à-dire plus de radiographies annotées afin d'augmenter son jeu d'entraînement. En effet, nous avons remarqué de moins bonnes performances du réseau sur les groupes ayant le moins de radios lors de l'apprentissage et au contraire, de meilleures performances sur les groupes avec plus de radiographie (Groupe Dents Lactéales : $n=46$, $Dice=0,52$; Groupe Incisivo-Canin $n=160$, $Dice=0,63$). Ajouter des données est un processus long et précis afin de pouvoir garantir le bon diagnostic des caries par les observateurs.

Les radiographies n'ont pas toutes été prises selon les recommandations avec l'utilisation d'un angulateur mais se rapprochent d'une qualité de radiographie issue d'une activité quotidienne. De plus, nous pouvons penser que le réseau pourra plus facilement identifier les lésions sur une radiographie avec angulateur par rapport aux radiographies sur lequel il a été entraîné.

L'utilisation de l'architecture du réseau de neurone à convolution U-Net++ (2018) montre de bons résultats dans la segmentation d'image médicale mais l'utilisation d'une nouvelle architecture plus récente pourrai possiblement améliorer les résultats tout comme une optimisation plus fine des hyper-paramètres de notre réseau.

Un autre paramètre de notre étude à améliorer est la définition de la référence des lésions carieuses que nous avons donnée. Cette référence ne s'est basée que sur mon analyse des radiographies, en m'aidant de la littérature.

Avoir un seul examinateur servant de référence peut, malgré plusieurs relectures, conduire à l'oubli de l'annotation de lésions ou à des erreurs de diagnostics. La participation de plusieurs examinateurs dont la moyenne de leurs annotations servirait de référence permettrait de réduire ces erreurs.

De plus, l'examen radiologique seul ne permet pas dans certaines situations de déterminer précisément l'avancement de la carie ou sa présence quand elle est débutante. Il serait préférable de corréliser chaque radiographie à une analyse du dossier médical du patient afin de savoir si l'interprétation d'une lésion sur une radiographie a bien pu être objectivée en bouche lors de l'examen clinique.

C. Forces de l'étude

L'étude que nous avons menée est la première étude portant sur l'application de réseaux de neurones à convolution dans le domaine de l'odontologie en France. Les nombreux progrès dans le domaine de l'intelligence artificielle et tout particulièrement des réseaux de neurones laissent à penser que notre étude n'est qu'un début, et que d'autres équipes vont se lancer sur ce sujet en France à l'avenir.

Malgré des résultats pouvant être sujet à amélioration, notre modèle a réussi à produire des résultats exploitables avec des valeurs métriques en progrès par rapport à d'anciens travaux. Le travail que nous avons fourni peut être repris et amélioré dans le cadre d'une thèse de recherche avec de meilleurs moyens techniques et des délais plus conséquents. En effet, le projet a dû être mené avec des moyens limités sur un délai de moins d'un an. Nous avons tout de même réussi à obtenir et analyser un nombre conséquent de radiographies (n=1375).

Le travail de programmation et d'adaptation du réseau u-Net++ déjà existant a été exclusivement mené à base de logiciels et programmes open-source. Le résultat final obtenu étant lui-même disponible en open-source, afin de respecter l'état d'esprit de partage des connaissances au service de la communauté.

V. Conclusion

La détection précoce des lésions carieuses est un élément important afin de pouvoir intervenir le plus rapidement possible et limiter l'atteinte des tissus de la dent. Cette détection peut avoir lieu suite à des signes cliniques ressentis par le patient ou bien lors d'un examen de routine.

La référence dans le diagnostic des caries reste l'examen clinique afin de pouvoir évaluer la présence et l'activité ou non de la lésion. Cependant l'analyse radiographique assistée par ordinateur pourrait servir d'aide lors du diagnostic et ainsi éviter des oublis de la part de l'opérateur humain lors de son analyse de la radiographie.

L'analyse des radiographies par intelligence artificielle n'est pas encore une technique au point utilisable en clinique car jusqu'à présent, aucune étude n'a pu avoir un seuil de détection suffisamment précis tout en évitant la présence de faux positifs et faux négatifs.

Pour parvenir jusqu'à une utilisation possible en clinique, en complément de l'opérateur humain, la recherche sur ce sujet doit se poursuivre. Cette dernière nécessite du temps, nécessaire à la récupération des données, leur analyse ainsi qu'à la mise en place de modèle et leur optimisation. Ainsi les équipes dédiées à ce sujet se doivent d'être composée d'experts en chirurgie-dentaire ou radiologie, selon la visée de l'étude, et d'ingénieurs en informatique experts en intelligence artificielle.

Nous pouvons noter une grande amélioration des performances des réseaux de neurones à convolution dans leur application médicale depuis les cinq dernières années. Cette amélioration est notamment due à l'augmentation de la puissance de calcul, l'augmentation du nombre de données disponibles ainsi qu'à l'émergence de nouvelles architectures accessibles aux équipes de recherche.

Notre étude porte sur une application de l'intelligence artificielle dans la segmentation de lésions carieuses mais il est possible d'appliquer la segmentation à tous les tissus de la cavité buccale avec comme application possible : la recherche de lésions endodontiques, parodontales à partir de radiographies ou encore l'aide au diagnostic de pathologies de la cavité buccale à partir de photos comme la recherche du lichen plan par exemple. L'analyse des tissus durs de la dent peut également être conduite à partir de photos issus d'une caméra à transillumination afin de détecter au plus vite les lésions carieuses débutantes.

L'application des réseaux de neurones à convolution comme aide au diagnostic en odontologie n'est pas encore utilisable en clinique mais reste un axe de recherche prometteur pour les années à venir. Ainsi il semble tout à fait réaliste d'imaginer dans un futur proche l'émergence d'applications de bureau, simples d'utilisation, pour les chirurgiens-dentistes afin de réduire les erreurs de diagnostic liées par exemple à la fatigue de l'opérateur.

Il convient néanmoins de souligner que la référence pour le diagnostic reste l'examen clinique et que jusqu'à preuve du contraire, cette technique ne peut être menée à bien que par un opérateur humain compétent.

Bibliographie

- [1] Global, regional, and national incidence, prevalence, and years lived with disability for 354 diseases and injuries for 195 countries and territories, 1990–2017: a systematic analysis for the Global Burden of Disease Study 2017. *Lancet* 2018; 392: 1789–8583.
- [2] De La Dure-Molla M, Naulin Ifi C, Eid Blanchot C. Carie et ses complications chez l'enfant. *EMC-Médecine buccale* 2012 ; 7(5) :1-11.
- [3] Fejerskov O, Nyvad B, Kidd E. *Dental Caries: The Disease and its Clinical Management*, 3rd Edition. Wiley-Blackwell ; 2015.
- [4] Whaites E, Drage N. *Radiographie et radiologie dentaires*, 5ème édition. Elsevier-Masson ; 2019.
- [5] Harrison M. Berry, Jr, Cervical Burnout and Mach band : two shadows of doubt in radiologic interpretation of carious lesion, *JADA*, 1983 May;106.
- [6] Zhang, W. J, Yang, G., Lin, Y., Ji, C., & Gupta, M. M. On Definition of Deep Learning. 2018 World Automation Congress (WAC).
- [7] Burkov A. *The Hundred-Page Machine Learning Book*. 2019.
- [8] Lee JH, Kim DH, Jeong SN, Choi SH. Detection and diagnosis of dental caries using a deep learning-based convolutional neural network algorithm. *J Dent*. 2018 Oct;77:106-111.
- [9] Kats L, Vered M, Blumer S, Kats E. Neural Network Detection and Segmentation of Mental Foramen in Panoramic Imaging. *J Clin Pediatr Dent*. 2020;44(3):168-173.
- [10] Boedi RM, Banar N, De Tobel J, Bertels J, Vandermeulen D, Thevissen PW. Effect of Lower Third Molar Segmentations on Automated Tooth Development Staging using a Convolutional Neural Network, *J Forensic Sci*, 2020 March;65(2) :481-486.
- [11] Ronneberger O, Fischer P, Brox T. *Dental X-ray Image Segmentation using a U-shaped Deep Convolutional Network*, 2014
- [12] Kim, J, Lee, HS., Song, IS. et al. DeNTNet: Deep Neural Transfer Network for the detection of periodontal bone loss using panoramic dental radiographs. *Sci Rep* 9, 2019 ;17615
- [13] Casalegno F, Newton T, Daher R, Abdelaziz M, Lodi-Rizzini A, Schürmann F, Krejci I, Markram H. Caries Detection with Near-Infrared Transillumination Using Deep Learning. *J Dent Res*. 2019 Oct;98(11):1227-1233
- [14] Sklan JE, Plassard AJ, Fabbri D, Landman BA. Toward Content Based Image Retrieval with Deep Convolutional Neural Networks. *Proc SPIE Int Soc Opt Eng*. 2015 Mar 19;9417:94172C.
- [15] Schwendicke F, Golla T, Dreher M, Krois J. Convolutional neural networks for dental image diagnostics: A scoping review. *J Dent*. 2019 Dec;91:103226.
- [16] Horner K, Rout J, Rushton VE, Wilson N. *Interpreting dental radiographs*. Quintessence ;2002.
- [17] Litzemberger F, Heck K, Pitchika V, Neuhaus KW, Jost FN, and al. Inter- and intraexaminer reliability of bitewing radiography and near-infrared light transillumination for proximal caries detection and assessment. *Dentomaxillofac Radiol*. 2018 Feb;47(3):20170292.

[18] Zhou Z, Siddiquee MMR, Tajbakhsh N, Liang J. UNet++: A Nested U-Net Architecture for Medical Image Segmentation. *Deep Learn Med Image Anal Multimodal Learn Clin Decis Support*. 2018 Sep;11045:3-11.

[19] Wang CW, Huang CT, Lee JH, Li CH, Chang SW, Siao MJ, Lai TM, Ibragimov B, Vrtovec T, Ronneberger O, Fischer P, Cootes TF, Lindner C. A benchmark for comparison of dental radiography analysis algorithms. *Med Image Anal*. 2016 Jul;31:63-76.

Annexe

Code source disponible :

<https://github.com/Momotoculteur/Tooth-decay-semantic-segmentation>

Collège des Sciences de la Santé

UFR des Sciences Odontologiques

Serment

En présence de mes Maîtres et de mes condisciples, je promets et je jure d'être fidèle aux lois de l'honneur et de la probité dans l'exercice de l'art dentaire.

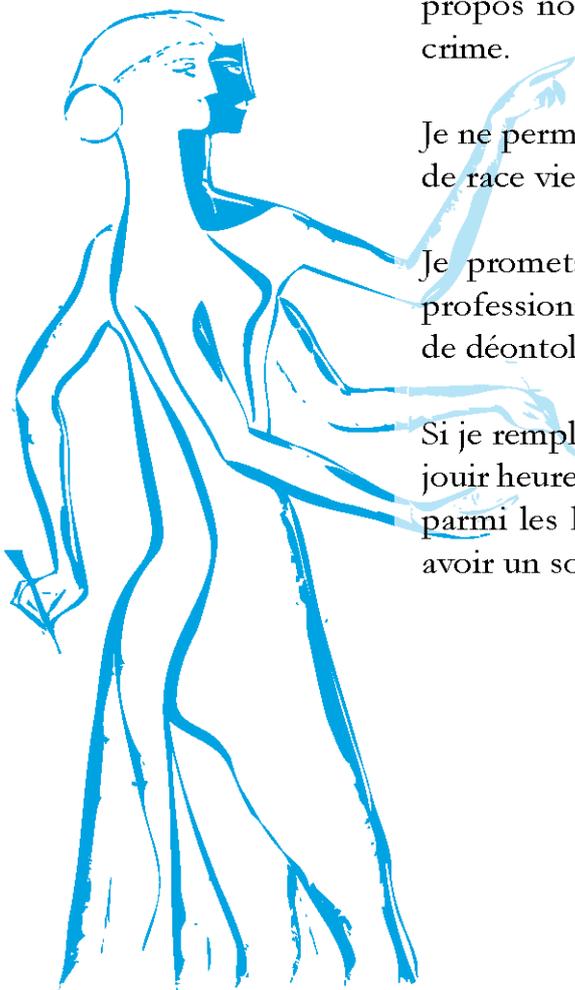
Je donnerai mes soins gratuits à l'indigent et n'exigerai jamais un honoraire au-dessus de mon travail. Ma langue taira les secrets qui me seront confiés. Admis à l'intérieur des maisons, mes yeux ne verront pas ce qui s'y passe.

Mes connaissances et mon état ne serviront ni à diffuser des propos non avérés, ni à corrompre les mœurs, ni à favoriser le crime.

Je ne permettrai pas que des conditions de croyance, de nation et de race viennent s'interposer entre mon devoir et mon patient.

Je promets et je jure de conformer strictement ma conduite professionnelle aux principes et aux règles prescrites par le code de déontologie.

Si je remplis ce serment sans l'enfreindre, qu'il me soit donné de jouir heureusement de la vie et de ma profession, honoré à jamais parmi les hommes. Si je le viole et que je me parjure, puissé-je avoir un sort contraire.



Vu, Le Président du Jury,

Date, Signature :

Vu, la Directrice de l'UFR des Sciences Odontologiques,

Date, Signature :

Vu, le Président de l'Université de Bordeaux,

Date, Signature :

Titre : Segmentation de lésions carieuses à partir de radiographies par un réseau de neurones à convolution

Résumé :

La détection précoce des lésions carieuses est un élément primordial dans le traitement de la maladie carieuse afin de pouvoir intervenir au plus vite et préserver les tissus dentaires. Le diagnostic de la maladie carieuse se fonde sur l'examen clinique mais la détection des lésions peut intervenir lors de l'examen radiographique. Depuis quelques années, le domaine de l'intelligence artificielle s'est étendu avec le développement des réseaux de neurones à convolution, dont certains spécialisés dans la détection et la segmentation d'images médicales. Le but de cette thèse était de programmer un réseau de neurones à convolution capable à partir d'une radiographie intrabuccale de détecter et segmenter les lésions carieuses. Mille trois cent soixante-quinze radiographies ont été analysées et les lésions carieuses segmentées. Ces données ont permis d'entraîner le réseau à segmenter les lésions et à tester ses performances. Les résultats obtenus montrent qu'il est possible d'obtenir un réseau fonctionnel avec des résultats exploitables. Cependant, les valeurs de sensibilité et spécificité mesurées traduisent trop d'erreurs de sous-diagnostic et donc une impossibilité de l'utiliser cliniquement. Ces résultats ont néanmoins démontré que les réseaux de neurones à convolution sont fonctionnels, applicables dans le domaine dentaire et qu'il apparaît nécessaire de continuer les recherches afin d'optimiser les résultats. La littérature s'accorde pour le moment sur le fait que l'intelligence artificielle ne peut remplacer l'humain dans le diagnostic des lésions carieuses.

Mots clés : Intelligence Artificielle, Carie, Apprentissage profond, Réseau de neurone à convolution, Apprentissage supervisé, Diagnostic Dentaire, Radiologie, Informatique Médicale

Title : Dental X-ray tooth decay segmentation using a convolutional neural network

Abstract :

The early detection of caries lesions is an essential aspect in the treatment of caries disease in order to be able to intervene as quickly as possible and preserve dental tissue. The diagnosis of caries disease is based on physical examination, but lesions may be detected on X-ray examination. In recent years, the field of artificial intelligence has expanded with the development of convolutional neural networks, some of which specialized in the detection and segmentation of medical images. The aim of this thesis was to program a convolutional neural network able to detect and segment caries lesions from an intraoral X-ray. One thousand three hundred and seventy-five radiographs were analyzed and the carious lesions segmented. These data were used to train the network to segment lesions and test its performance. The results obtained show that it is possible to obtain a functional network with actionable results. However, the values of sensitivity and specificity measured reflect too many errors of underdiagnosis and therefore an inability to use it clinically. These results nevertheless demonstrated that convolutional neural networks are functional, applicable in the dental field and it appears necessary to continue research in order to optimize the results. The literature currently agrees that artificial intelligence cannot replace humans in the diagnosis of caries lesions.

Keywords : Artificial Intelligence, Caries, Deep Learning, Convolution Neural Network, Supervised Learning, Dental Diagnosis, Radiology, Medical Informatics