

UNIVERSITÉ DE NANTES  
UNITÉ DE FORMATION ET DE RECHERCHE D'ODONTOLOGIE

Année 2021

N° 3735

# **DETECTION ET CLASSIFICATION AUTOMATIQUE DES DENTS SUR LES RADIOGRAPHIES DENTAIRES**

THÈSE POUR LE DIPLÔME D'ÉTAT DE  
DOCTEUR EN CHIRURGIE DENTAIRE

*présentée  
et soutenue publiquement par*

**WEYDER Mathias**

*Le 21 juin 2021 devant le jury ci-dessous*

*Président* : Monsieur le Professeur Yves AMOURIQ

*Assesseur* : Monsieur le Professeur Laurent LE GUEHENNEC

*Assesseur* : Monsieur le Professeur Jean-Pierre GUEDON

*Directeur de thèse* : Madame le Docteur Fabienne JORDANA

*Co-directeur* : Monsieur le Professeur Yves AMOURIQ

<b>UNIVERSITE DE NANTES</b>	
<u>Président</u> <b>Pr BERNAULT Carine</b>	
 <small>UNIVERSITE DE NANTES</small>	
<b>FACULTE DE CHIRURGIE DENTAIRE</b>	
<u>Doyen</u> <b>Pr GIUMELLI Bernard</b>	
 <small>Faculté de Chirurgie Dentaire NANTES</small>	
<u>Assesseurs</u> Dr RENAUDIN Stéphane Pr SOUEIDAN Assem Pr WEISS Pierre	
<b>PROFESSEURS DES UNIVERSITES</b>	
<b>PRATICIENS HOSPITALIERS DES C.S.E.R.D.</b>	
Mme ALLIOT-LICHT Brigitte M. AMOURIQ Yves M. BADRAN Zahi M. GIUMELLI Bernard M. LABOUX Olivier M. LE GUEHENNEC Laurent	M. LESCLOUS Philippe Mme LOPEZ-CAZAUX Serena Mme PEREZ Fabienne M. SOUEIDAN Assem M. WEISS Pierre
<b>PROFESSEURS DES UNIVERSITES</b>	
M. BOULER Jean-Michel	
<b>MAITRE DE CONFERENCES DES UNIVERSITES</b>	
Mme VINATIER Claire	
<b>PROFESSEURS EMERITES</b>	
M. JEAN Alain	
<b>ENSEIGNANTS ASSOCIES</b>	
M. GUIHARD Pierre (Professeur Associé)	Mme LOLAH Aoula (Assistant Associé)
<b>MAITRES DE CONFERENCES DES UNIVERSITES</b> <b>PRATICIENS HOSPITALIERS DES C.S.E.R.D.</b>	<b>ASSISTANTS HOSPITALIERS UNIVERSITAIRES DES</b> <b>C.S.E.R.D.</b>
M. AMADOR DEL VALLE Gilles Mme ARMENGOL Valérie Mme BLERY Pauline M. BODIC François Mme CLOITRE Alexandra Mme DAJEAN-TRUTAUD Sylvie M. DENIS Frédéric Mme ENKEL Bénédicte M. GAUDIN Alexis M. HOORNAERT Alain Mme HOUCHMAND-CUNY Madline Mme JORDANA Fabienne M. LE BARS Pierre M. NIVET Marc-Henri M. PRUD'HOMME Tony Mme RENARD Emmanuelle M. RENAUDIN Stéphane Mme ROY Elisabeth M. STRUILLOU Xavier M. VERNER Christian	M. ALLIOT Charles Mme ARRONDEAU Mathilde Mme CLOUET Roselyne M. EVRARD Lucas M. GUIAS Charles M. GUILLEMIN Maxime Mme HASCOET Emilie Mme HEMMING Cécile M. HIBON Charles M. KERIBIN Pierre Mme OYALLON Mathilde Mme QUINSAT Victoire Eugenie M. REMAUD Matthieu M. RETHORE Gildas M. SERISIER Samuel Mme TISSERAND Lise
<b>PRATICIENS HOSPITALIERS</b>	
Mme DUPAS Cécile	Mme HYON Isabelle
<b>ATTACHÉS HOSPITALIERS</b>	
M. ELHAGE Louis-Marie M. GLOMET Jérémy Mme PAGBE NDOBO Pauline Mme PREVOT Diane	Mme RICHARD Catherine M. SARKISSIAN Louis-Emmanuel M. STRUBE Nicolas

**Par délibération, en date du 6 décembre 1972, le Conseil de 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'il n'entend leur donner aucune approbation, ni improbation**

## **Remerciements**

**A Madame le Docteur JORDANA Fabienne,**

Maître de Conférences des Universités - Praticien Hospitalier des Centres de Soins  
d'Enseignement et de Recherche Dentaires

Docteur de l'Université de Bordeaux

Habilitée à Diriger les Recherches

Département de Sciences Anatomiques et Physiologiques, Occlusodontiques, Biomatériaux,  
Biophysique, Radiologie

- NANTES -

## **Remerciements**

**A Monsieur le Professeur AMOURIQ Yves,**

Professeur des Universités - Praticien Hospitalier des Centres de Soins d'Enseignement et de Recherche Dentaires

Docteur de l'Université de Nantes

Habilité à Diriger les Recherches

Département de Prothèses

Chef de Service d'Odontologie Restauratrice et Chirurgicale

- NANTES -

## **Remerciements**

**A Monsieur le Professeur LE GUEHENNEC Laurent,**

Professeur des Universités - Praticien Hospitalier des Centres de Soins d'Enseignement et de Recherche Dentaires

Docteur de l'Université de Nantes

Habilité à Diriger les Recherches

Chef du Département de Prothèses

- NANTES -

## Remerciements

**A Monsieur le Professeur GUEDON Jean-Pierre,**

Professeur des Universités en Informatique - Polytech Nantes

Docteur de l'Université de Nantes

Habilité à Diriger les Recherches

- NANTES -

## Table des matières

1. Introduction.....	10
2. L'analyse d'images en informatique .....	13
1. Réseaux de neurones convolutifs.....	13
1. Présentation .....	13
2. Couche de convolution.....	13
3. Couche de regroupement .....	15
4. Couche entièrement connectée.....	16
2. Classification et identification .....	17
3. Évaluer un modèle.....	18
3. Applications de l'intelligence artificielle dans l'imagerie en odontologie .....	20
1. Objectif.....	20
2. Odontologie conservatrice .....	20
1. Détection de lésions carieuses .....	20
2. Détection de lésions péri-apicales.....	21
3. Parodontologie .....	21
4. Odontologie médico-légale .....	23
1. Évaluation de l'âge d'un individu .....	23
2. Identification d'une personne <i>post-mortem</i> .....	24
3. Réalisation d'un schéma dentaire .....	24
5. Chirurgie .....	25
4. Développement d'un système d'annotation automatique des radiographies dentaires.....	28
1. Objectif.....	28
2. Collection du jeu de données.....	28
3. Annotation du jeu de données.....	28
4. Augmentation du jeu de données.....	29
5. Modèles de réseaux de neurones de convolution .....	30
6. Apprentissage des paramètres du modèle .....	31
7. Évaluation des performances des modèles de classification .....	33
8. Détection des dents .....	33
9. Identification et classification des dents.....	34
10. Présentation des résultats de prédictions sur des radiographies dentaires.....	35

11.	Perspectives.....	38
5.	Conclusion .....	39
6.	Bibliographie.....	40
7.	Table des illustrations.....	44
8.	Liste des tableaux.....	45

# 1. Introduction

La radiographie dentaire est l'outil majeur pour l'aide au diagnostic clinique, afin d'évaluer le besoin d'un traitement et la qualité d'un soin. De nombreux travaux ont été consacrés au développement de systèmes d'analyse automatisés d'images radiographiques dentaires afin d'améliorer la qualité de l'analyse clinique. En effet, les systèmes d'assistance médicale dans l'analyse d'images sont de plus en plus répandus grâce aux progrès récents de la recherche en informatique, notamment dans le domaine de l'apprentissage automatique (1) (2) (3).

L'intelligence artificielle est une science formant une branche à l'interface des mathématiques et de l'informatique, qui se définit comme le développement de théories et de systèmes informatiques capables d'exécuter des tâches traditionnellement effectuées à l'aide de l'intelligence humaine (4). L'intelligence artificielle utilise des modèles de calcul qui peuvent penser et agir intelligemment avec des mécanismes similaires ceux du cerveau humain et utiliser des procédures qui peuvent apprendre des données (données dites d'apprentissage) afin de réaliser des actions, des prédictions sur de nouvelles données, dans un nouveau contexte.

L'intelligence artificielle est ainsi devenue extrêmement courante dans des domaines aussi nombreux que divers comme la reconnaissance faciale, la reconnaissance vocale, la reconnaissance automatique d'objets pour les voitures autonomes, la classification automatique de courriels ou bien encore l'analyse automatique de textes (5) (6).

Le *deep learning*, ou apprentissage profond, constitue un sous-ensemble de l'intelligence artificielle : il explore la construction de méthodes capables d'apprendre à partir de grandes quantités de données, de découvrir des motifs à l'intérieur de ces données, puis de faire des prédictions (7). Ces méthodes de *deep learning* sont construites selon un ensemble d'instructions informatiques destinées à effectuer une tâche particulière, également nommé algorithme. Le *deep learning* repose ainsi sur la construction d'algorithmes complexes permettant à la machine d'apprendre par elle-même à partir de données aussi diverses que des images, des vidéos ou de tableaux de données. Le *deep learning* repose fondamentalement sur des algorithmes guidés par des données.

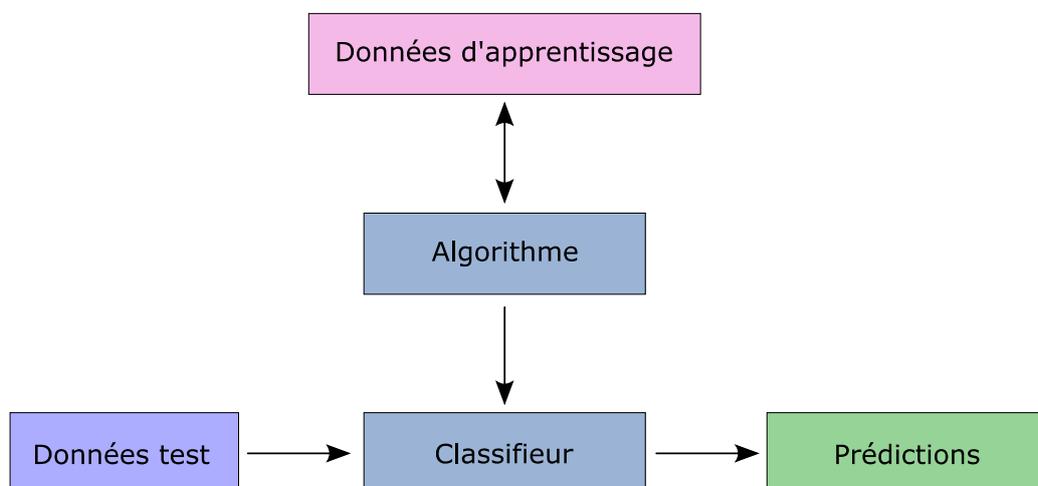
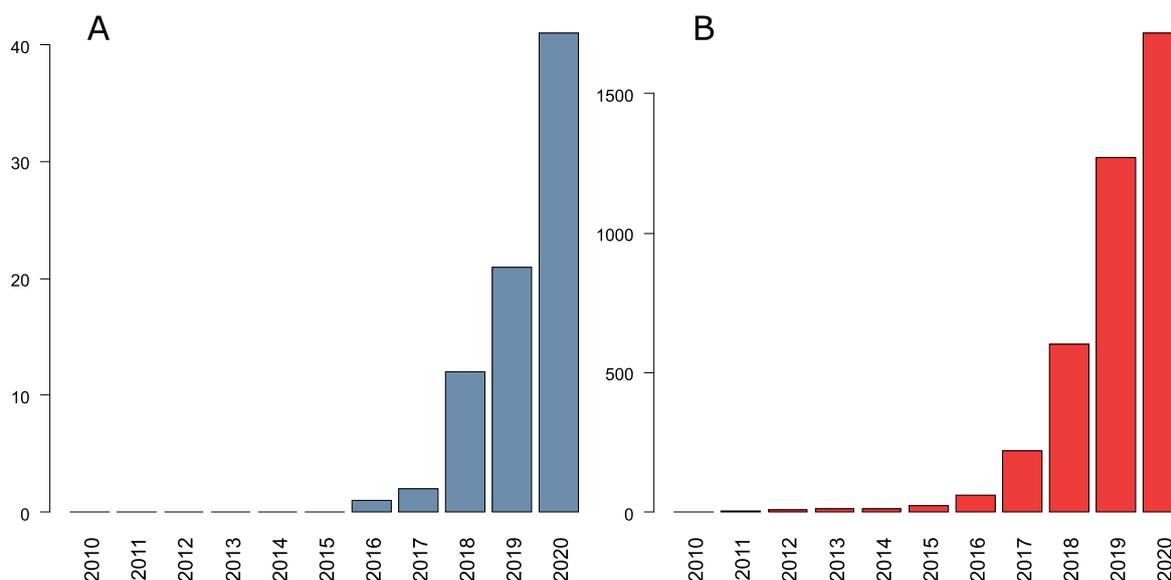


Figure 1. Schéma décrivant le fonctionnement de l'apprentissage supervisé en *deep learning*.

L'apprentissage supervisé est un domaine du *deep learning* consistant à déduire une fonction à partir de données annotées (8). Les données d'entraînement du modèle se composent d'un ensemble d'exemples appelés données d'apprentissage (**Figure 1**). En apprentissage supervisé, chaque exemple est constitué d'un objet d'entrée (généralement une matrice représentant les pixels de l'image) et d'une valeur de sortie qui est la classification de cet objet. L'algorithme d'apprentissage analyse alors les données d'entraînement, puis produit une fonction qui est ensuite utilisée pour catégoriser de nouveaux exemples. L'algorithme apprend ainsi à partir des données, d'où le terme d'intelligence artificielle. Les performances des modèles ou classifieurs de *deep learning* sont optimisées avec une quantité importante d'exemples (généralement plusieurs milliers) fournis à l'algorithme lors de la phase d'apprentissage.

Ainsi, en radiologie, l'apprentissage profond a trouvé sa place, notamment en raison de sa capacité à détecter les anomalies dans les images radiographiques qui peuvent ne pas être remarquées à l'œil nu. Ces systèmes pourront, dans un futur proche, probablement réduire la charge de travail des radiologues en traitant plus rapidement les données et en surveillant par exemple la réponse à un traitement avec un risque d'erreur réduit lié à un biais cognitif (9) (10). Cependant, dans le domaine médical, l'application des algorithmes d'analyse d'images est souvent limitée, non pas par la quantité de données qui sont réalisées quotidiennement en nombre en routine clinique, mais par la disponibilité d'un jeu de données annotées par un expert du domaine : cela constitue une limite majeure, ce manque de disponibilité des données annotées ne faisant pas exception en odontologie.



**Figure 2. Nombre de publications annuelles dans la base de données PubMed en septembre 2020.** (A) Contenant les mots-clés *dental*, *deep learning* et *image*. (B) Contenant les mots-clés *medical*, *deep learning* et *image*.

Comme observé en **Figure 2**, on remarque une croissance exponentielle du nombre de publications traitant de l'analyse d'images par des méthodes de *deep learning*, aussi bien en médecine qu'en odontologie qui suivent la même tendance depuis ces dernières années.

Cette forme avancée d'apprentissage est, entre autres, portée par l'utilisation de réseaux neuronaux (11), chef de file des algorithmes dans l'analyse automatique et dans la reconnaissance de motifs

dans des images ou les vidéos. Ces programmes sont principalement utilisés pour traiter des images volumineuses et complexes telles que les radiographies 2D ou les images 3D. Alors que diverses architectures d'apprentissage supervisé ont été explorées pour traiter des problèmes d'analyse d'images, les réseaux de neurones convolutifs comptent parmi les modèles d'architecture d'apprentissage en profondeur les plus répandus aujourd'hui en imagerie médicale, et plus particulièrement en radiographie dentaire (12) (13).

L'objectif de ce travail est de fournir une meilleure compréhension de l'apport de l'intelligence artificielle dans la problématique de l'analyse automatique d'images radiographiques en odontologie.

Dans un premier temps, nous détaillerons les réseaux de neurones convolutifs qui constituent le formalisme de modélisation le plus utilisé dans l'analyse d'images, puis, dans un second temps, nous réaliserons une revue de la littérature des approches utilisant le *deep learning* dans l'analyse d'examens radiographiques en détaillant leur champ d'application en odontologie. Enfin, dans un troisième temps, nous présenterons un travail qui a consisté à développer un programme détectant les organes dentaires sur des clichés radiographiques rétro-alvéolaires et à classifier ces derniers.

## 2. L'analyse d'images en informatique

### 1. Réseaux de neurones convolutifs

#### 1. Présentation

Les réseaux neuronaux convolutifs constituent un domaine de recherche à l'interface entre les sciences informatiques et médicales, domaine qui a émergé récemment et donné de très bons résultats en matière de diagnostic et de prédiction, plus particulièrement dans les domaines de la radiologie et de la pathologie. Ces dernières années, ils sont devenus extrêmement populaires en obtenant des résultats très impressionnants dans la reconnaissance d'images, impactant profondément le domaine de l'analyse d'images par ordinateur (7) (14) (15).

Pour résumer, l'objectif d'un réseau de neurones convolutifs est d'extraire la caractéristique de l'image et de la convertir en une image de dimension inférieure, sans en perdre les caractéristiques. Un réseau neuronal de convolution apprend directement à partir des données, reconnaît les motifs dans les images et, finalement, classe ces dernières en catégories, *a priori* déterminées.

Les réseaux de neurones convolutifs sont des réseaux d'apprentissage profonds qui se composent de plusieurs blocs de calculs superposés, à savoir des couches appelées de convolution (*convolution layers*), des couches de mise en commun (*pooling layer*) et des couches connectées (*connected layers*).

#### 2. Couche de convolution

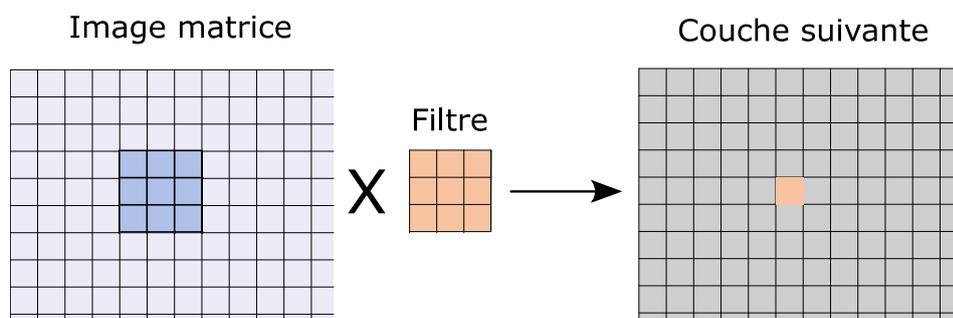
La première couche (la couche de convolution) permet d'extraire les caractéristiques de l'image. Un ensemble de paramètres (appelés filtres, noyaux ou bien *kernels*), représentés sous la forme d'une matrice, sont appliqués à chaque position d'image pour obtenir un signal modifié. Les paramètres de ces filtres sont optimisés par le processus connu sous le nom de rétro-propagation qui sera expliqué un peu plus loin.

La couche de convolution permet, au travers de ces filtres, d'extraire les caractéristiques de l'image, c'est-à-dire de retrouver des fragments d'images communs à plusieurs images (comme les bords, les lignes, les variations de couleur). Les caractéristiques rassemblent alors les aspects les plus fréquemment retrouvés. Ainsi, une première couche convolutive peut apprendre des éléments de base tels que des arêtes, et une seconde couche convolutive peut décomposer les éléments appris précédemment de façon plus précise, et ainsi de suite. Cela permet aux réseaux de neurones convolutifs d'apprendre efficacement des concepts visuels de plus en plus complexes et abstraits dans les couches les plus profondes.

Les images fournies au réseau de neurones sont vues comme des matrices composées de trois dimensions : deux axes représentent la surface de l'image, le troisième, appelé profondeur, décrit sa couleur ; la hauteur de l'image est le nombre de lignes de la matrice, la largeur le nombre de colonnes et la profondeur correspond aux trois canaux de chromatiques (RVB). En effet, pour une image en couleurs, la dimension de l'axe de profondeur est de trois car l'image possède trois canaux : rouge, vert et bleu ; pour une image en noir et blanc, ce qui est le cas dans la radiographie médicale, la dimension de l'axe de profondeur est de un car l'image n'est décrite que par des niveaux de gris.

L'opération de convolution est appliquée à une partie de l'image en calculant le produit scalaire entre une région locale de l'image et le filtre, représenté par une matrice. La taille de la sous-image, représentée sous la forme d'une matrice, est donc la même que celle du filtre afin de pouvoir effectuer le produit scalaire.

La valeur de chaque point de la couche suivante sera donc égale au produit scalaire entre la région de l'image considérée, également appelée couche d'entrée, et le filtre, suivi par une somme de ces valeurs (**Figure 3**).

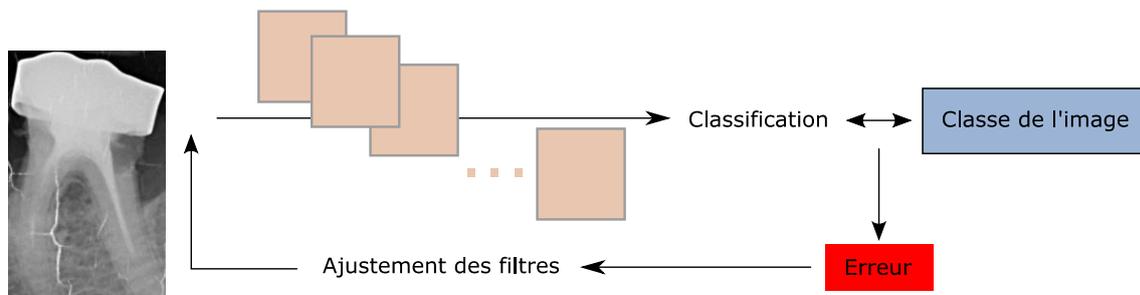


**Figure 3. Illustration de l'application d'un filtre ou matrice de convolution.**

Le filtre glisse ensuite le long de l'image du haut à gauche et la passe de gauche à droite et du haut vers le bas, pixel par pixel, en appliquant une l'opération de convolution et continue la même opération. Le processus est répété jusqu'à ce que toute l'image soit parcourue. La matrice générée en sortie sera l'entrée pour la couche suivante. Il est important de noter que le même filtre est utilisé pour générer toutes les valeurs de la couche suivante. Le nombre de paramètres sera donc égal à la taille de la matrice composant le filtre.

Ainsi, le signal d'entrée est multiplié par le filtre pour obtenir un signal modifié. Il va sans dire que la quantité de calculs réalisés peut s'accroître de façon exponentielle en fonction du nombre de filtres utilisés et de la résolution des images fournies au réseau.

Les poids des filtres ne sont pas définis manuellement mais calculés par un algorithme appelé rétro-propagation qui vise à optimiser ces valeurs (**Figure 4**). Pour cela, une collection d'images dont nous connaissons déjà la catégorie doit être disponible, appelée aussi jeu de données d'apprentissage. Un ensemble de filtres générés de façon aléatoire est d'abord appliqué à l'image. Pour chaque image analysée par le réseau de neurones, on obtient une classification. Le nombre d'erreurs alors réalisées par le réseau renseigne sur la qualité des poids des filtres utilisés. Les poids sont alors ajustés de manière à réduire l'erreur de classification sur les données d'apprentissage. Les valeurs des filtres sont ajustées à chaque itération de l'algorithme, et si l'erreur globale de prédiction sur l'ensemble des images diminue, les ajustements sont conservés.



**Figure 4. Schéma décrivant le processus d'apprentissage du réseau de neurones.**

À chaque itération, les filtres produisant les images avec les meilleures correspondances sont appris. Ce processus s'appelle extraction de caractéristiques. Ce processus est réalisé pour chacune des couches convolutives et, à chaque itération, l'algorithme permet d'obtenir une réponse légèrement plus performante dans la classification des images d'apprentissage.

Mais un filtre ne permet de détecter qu'une caractéristique spécifique dans une image ; afin de réaliser une reconnaissance d'image, plusieurs filtres sont utilisés simultanément, générant autant de couches de convolution que de filtres choisis. Ainsi, une couche convolutive complète dans un réseau neuronal convolutif comprend plusieurs filtres. Les éléments qui n'apparaissent que dans de rares images sont rapidement oubliés, mais les motifs régulièrement retrouvés dans un grand nombre d'images sont retenus par les filtres.

### 3. Couche de regroupement

Outre les couches convolutives que nous venons de décrire, les couches de regroupement sont généralement appliquées immédiatement après les couches convolutives.

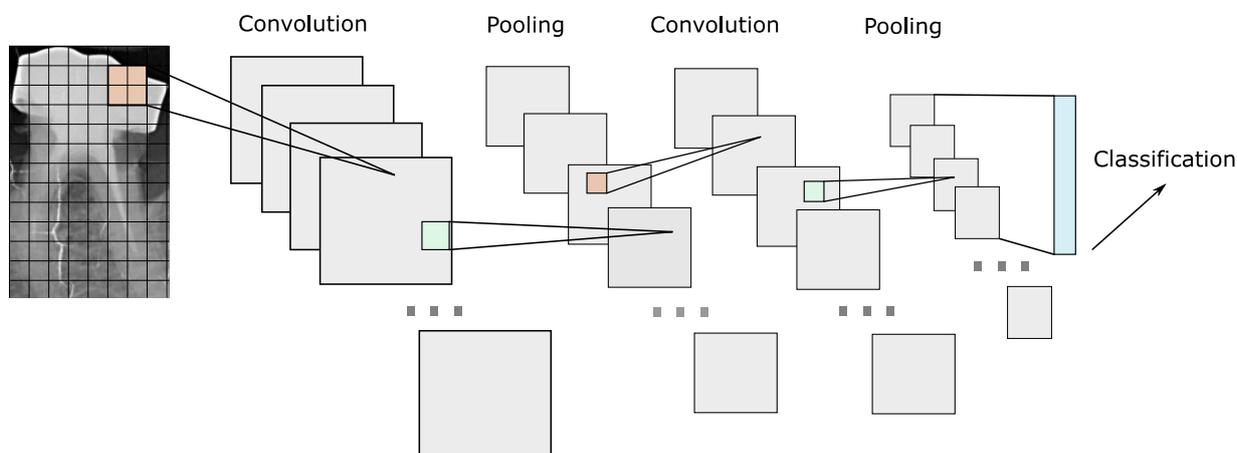
En effet, un jeu de données avec de nombreuses catégories d'objets différents nécessite un grand nombre de filtres, chacun responsable de la recherche d'un motif dans l'image. Plus de filtres signifie une dimensionnalité de la couche convolutive plus importante. L'étape de convolution augmente la dimension des données, conduisant à un accroissement exponentiel du nombre de calculs à réaliser.

Les couches de regroupement simplifient les informations collectées par les couches convolutives et créent une version condensée des informations que ces dernières contiennent. La mise en commun est le moyen de réduire le volume spatial de l'image d'entrée. La couche de regroupement effectue des opérations de sous-échantillonnage et réduit le nombre de paramètres du réseau. Elle est utilisée entre deux couches de convolution. On obtient une représentation moins précise de l'image, mais qui possède l'avantage d'être de dimension moindre.

Il existe plusieurs façons de condenser les informations ; la méthode la plus courante, connue sous le nom de *max-pooling*, conserve simplement la valeur maximale des valeurs se trouvant dans la fenêtre échantillonnée de la matrice de convolution. Ainsi, une fenêtre échantillonnée de  $2 \times 2$  divisera par 2 la taille de la sortie de la couche de regroupement. La couche de pooling est appliquée à autant de filtres convolutifs qu'il existe.

Ces opérations sont ensuite répétées avec des phases de convolution-pooling-convolution, etc. On obtient ainsi des données de plus petites dimensions et qui ont une bonne représentation abstraite

des contenus des différentes régions de l'image à classifier. Une manière habituelle de représenter visuellement l'ensemble de ces couches est illustrée dans la **Figure 5**, où les filtres précédemment décrits sont successivement appliqués.



**Figure 5. Explication des couches de convolution et de pooling lors de l'application de réseaux de neurones convolutifs à une image.**

Les filtres appliqués successivement aux matrices représentant l'image sont colorés en orange. Les phases de regroupement sont colorées en vert.

À partir de ces différents éléments, plusieurs architectures peuvent être considérées en faisant varier, par exemple, le nombre de couches du réseau de neurones, la taille des filtres ou encore la taille de la fenêtre utilisée dans la couche de pooling, ce qui permet de générer une infinité de combinaisons possibles.

#### 4. Couche entièrement connectée

La dernière couche du réseau est une couche entièrement connectée. Le but de la couche entièrement connectée est d'aboutir à la classification des images entre les différentes catégories, à partir des matrices de convolution obtenues précédemment.

L'entrée de la couche entièrement connectée est la sortie de la couche finale de regroupement ou de convolution précédente, qui est alors transformée de matrice en vecteur linéaire afin de générer cette couche entièrement connectée. La couche entièrement connectée est la même que celle des réseaux de neurones artificiels et les mêmes opérations mathématiques sont appliquées :

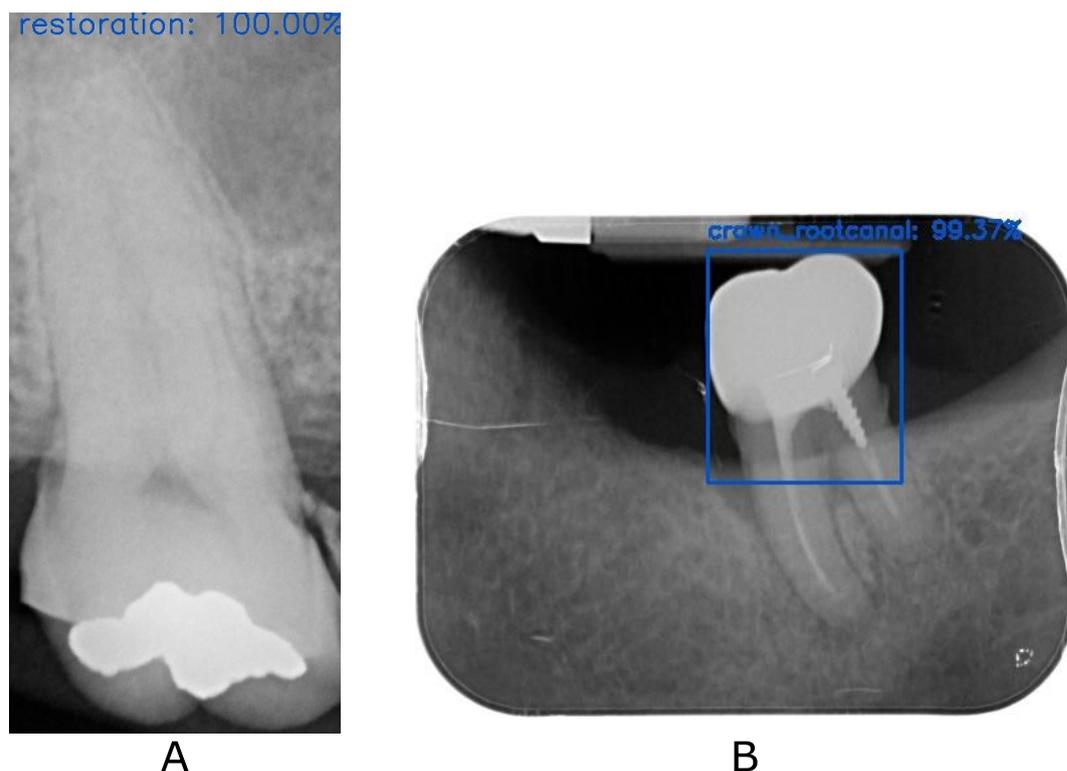
$$g(Wx + b)$$

Où  $x$  est le vecteur linéaire d'entrée,  $W$  est une matrice pondérée,  $b$  un vecteur de correction de biais et  $g$  la fonction d'activation. La pondération appliquée sert à déterminer la classe de l'image. Les poids sont ajustés via un algorithme de rétro-propagation comme pour les filtres de convolution et sont ajustés pour minimiser l'erreur de classification.

Cette dernière fonction d'activation classe alors les images en catégories *a priori* déterminées et fournit les probabilités d'appartenance de l'image aux différentes classes.

## 2. Classification et identification

Il est important de distinguer les concepts de classification et d'identification lors des études d'analyse d'images en fonction des objectifs que l'on souhaite atteindre et de la problématique à laquelle l'on souhaite répondre.



**Figure 6. Différence entre une classification et une identification.**

(A) Exemple de classification d'une dent restaurée. (B) Exemple d'une identification d'une dent couronnée et déulpée obtenue à partir du modèle développé dans la suite du travail.

Lors de la classification d'une image, à partir d'une image d'entrée, lorsque celle-ci est présentée à un réseau de neurones, nous obtenons une étiquette de classe unique et une probabilité associée à la prédiction d'étiquette de classe (**Figure 6, A**). Cette étiquette de classe est destinée à caractériser le contenu de l'image entière, ou du moins le contenu visible le plus dominant et occupant la plus grande partie de l'image. On obtient ainsi une image en entrée et une étiquette de classe en sortie.

En revanche, la détection d'objet nous indique non seulement ce qu'il y a dans l'image (c'est-à-dire l'étiquette de classe), mais également où se trouve l'objet dans l'image via un cadre contenant les coordonnées (x, y) de la région d'intérêt (**Figure 6, B**). À partir d'une image d'entrée, l'algorithme fournit :

- un ensemble de cadres où figurent les coordonnées (x, y) pour chaque objet de l'image,
- le libellé de classe associé à chacun des cadres,

- le score de confiance associé à chaque libellé de classe.

Ainsi, les tâches de détection d'objets apparaissent plus complexes et plus difficiles à mettre en œuvre par rapport aux réseaux traditionnels de classification des images. Sans les détailler, les chefs de file dans les tâches de détection d'objets dans les images sont les algorithmes suivants :

- R-CNN (16)
- Faster R-CNN (17)
- Mask R-CNN (18)
- Single Shot Detectors (SSD) (19)
- YOLO (20)

L'ensemble de ces travaux de recherche en informatique ont été publiés entre 2014 et 2017, ce qui atteste que cette thématique suscite un intérêt réel dans la recherche en analyse d'images.

### 3. Évaluer un modèle

Enfin, une fois l'architecture du modèle établie et la phase d'apprentissage réalisée, il va être nécessaire d'évaluer les performances du modèle. Cette évaluation permettra de comparer différentes architectures de modèles, ou bien encore de comparer un modèle par rapport à l'existant dans la littérature scientifique. Plusieurs mesures sont disponibles afin d'évaluer la performance d'un modèle. Il va sans dire que le réseau de neurones est validé sur un jeu de données indépendant, toujours annoté par un expert du domaine mais non utilisé lors de la phase d'apprentissage.

Tout d'abord, la sensibilité d'un test diagnostique représente sa capacité à détecter un maximum de cas, c'est-à-dire à réduire le nombre de faux négatifs au minimum. Autrement dit, il s'agit de la proportion de vrais positifs correctement identifiés en tant que tels.

$$\frac{\text{Vrai positif}}{\text{Vrai positif} + \text{Faux Négatif}}$$

La spécificité, parfois aussi appelée précision, d'un modèle est sa capacité à ne détecter que les cas recherchés. Autrement dit, il s'agit de minimiser la proportion de faux positifs.

$$\frac{\text{Vrai positif}}{\text{Vrai positif} + \text{Faux Positif}}$$

Enfin, le score F1 peut être interprété comme une moyenne pondérée de la sensibilité et de la spécificité, où un score F1 atteint son maximum avec une valeur à 1 et son minimum avec un score à 0. Ainsi, la contribution relative de la sensibilité et de la spécificité au score F1 est la suivante :

$$2 \times \frac{\text{Spécificité} \times \text{Sensibilité}}{\text{Spécificité} + \text{Sensibilité}}$$



### **3. Applications de l'intelligence artificielle dans l'imagerie en odontologie**

#### **1. Objectif**

L'objectif de cette partie est de réaliser un état de l'art de l'utilisation de l'intelligence artificielle dans l'imagerie en odontologie clinique. Les champs d'application de ces approches ont été déclinés au travers de quatre champs disciplinaires où ces méthodes ont été principalement utilisées, à savoir l'odontologie conservatrice, la parodontologie, l'odontologie légale et enfin la chirurgie. Pour chaque article, nous avons essayé d'en extraire les objectifs, les méthodes mises en place mais aussi les limites d'application.

#### **2. Odontologie conservatrice**

##### **1. Détection de lésions carieuses**

La maladie carieuse peut parfois être délicate à identifier à l'aide d'un examen clinique par inspection visuelle-tactile et nécessite alors des examens paracliniques comme les examens radiographiques (21). Une revue systématique a montré que, sur la base de 117 études utilisant les données de 13 375 dents, la détection des lésions initiales et avancées avait une sensibilité moyenne comprise entre 0,24 et 0,43, tandis que la spécificité moyenne variait entre 0,89 et 0,97, c'est-à-dire que les modèles sont peu sensibles mais l'occurrence de faux positifs est relativement rare (22). De plus, il est prouvé que les praticiens plus expérimentés ont une précision de détection améliorée par rapport aux examinateurs moins expérimentés ; les examinateurs expérimentés ont jusqu'à quatre fois plus de chances de détecter correctement les lésions carieuses proximales que les examinateurs peu expérimentés (23). Ainsi, les systèmes d'assistance automatisés pour l'imagerie radiographique dentaire pourraient atténuer ces biais, permettant une évaluation plus fiable et plus précise des lésions carieuses.

Srivastava et collaborateurs ont ainsi publié en 2017 un premier modèle permettant l'annotation automatique de lésions carieuses sur des radiographies rétro-coronaires (24). Une base de données constituée de 3 000 radiographies rétro-coronaires a été annotée afin de réaliser le modèle formulé sous la forme d'un réseau de neurones convolutifs de plus d'une centaine de couches. Le modèle obtient une sensibilité plus élevée que celle des praticiens, mais il s'avère néanmoins moins précis avec un nombre de faux positifs plus élevé que celui des experts.

Choi et collaborateurs se sont attachés à la détection des caries inter-proximales (25). La méthode développée est basée sur l'extraction des limites des couronnes dentaires puis l'utilisation d'un réseau de neurones. Une dernière étape permet de privilégier la recherche dans les zones en périphérie des couronnes dentaires ainsi que d'éliminer le chevauchement des zones annotées. Cependant, la quantité de données utilisées n'est pas mentionnée ni même les performances d'identification sur des radiographies tests.

En 2018, Lee et collaborateurs ont publié un modèle de réseaux neuronaux convolutifs capable de détecter mais aussi de diagnostiquer les caries à partir des radiographies dentaires (26). La précision du modèle varie entre 82 % et 89 % selon la position de la dent considérée.

Dans l'approche la plus récente, 3 293 radiographies rétro-coronaires ont été annotées par 4 dentistes seniors et ont ainsi permis de paramétrer un réseau de neurones convolutifs (27). Outre l'identification, une classification a été réalisée en distinguant trois classes : carie du tiers superficiel,

moyen ou profond de la couronne. Avec une précision de 0,80 et une sensibilité de 0,75, les performances du réseau sont significativement supérieures à celles des experts, obtenant respectivement une moyenne de 0,71 et 0,36.

Ainsi, l'examen clinique peut être insuffisant sur les surfaces non accessibles comme les zones interproximales, et une détection précoce par radiologie couplée à un algorithme de détection comme les CNN pourrait permettre une intervention plus précoce et moins invasive.

## **2. Détection de lésions péri-apicales**

Les granulomes ou kystes péri-apicaux constituent des lésions fréquemment rencontrées en clinique. Bien que la plupart de ces lésions soient visibles sur les radiographies, elles peuvent toutefois être difficiles à identifier à cause d'un faible contraste du cliché, de superposition avec des éléments anatomiques, ou à distinguer des trabéculations de l'os alvéolaire. Il n'existe pour l'instant qu'un seul article fournissant une aide au diagnostic automatique de lésions péri-apicales (28). À partir d'un modèle composé de 7 couches de convolution, les auteurs obtiennent de plutôt bonnes performances bien que le modèle soit assez peu sensible (0.65 sensibilité et 0.87 spécificité). Cependant, l'on peut supposer que l'annotation des experts puisse être partiellement inexacte, car l'annotation du jeu de données s'avère différente selon l'expert considéré et, dans les cas litigieux, elle n'est pas validée par un CBCT qui s'avérerait être un examen plus précis afin d'être sûr de l'annotation initiale. En effet, la reproductibilité de l'annotation inter-évaluateurs est de 0,48, donc plutôt faible, et dans les cas de désaccords, l'image a été supprimée du jeu de données. Dans le futur, la segmentation automatisée des lésions péri-apicales sera très probablement amenée à être développée.

## **3. Parodontologie**

Les pathologies parodontales constituent, dans leurs formes aiguës et chroniques, les premières causes de perte des organes dentaires chez l'adulte. Les pathologies infectieuses comme la gingivite et la parodontite font partie des maladies les plus courantes : la parodontite est la 6<sup>e</sup> maladie inflammatoire la plus répandue dans le monde (29). De plus, la maladie parodontale entretient des liens directs avec des maladies systémiques telles que les pathologies cardiovasculaires, respiratoires, endocriniennes ou musculo-squelettiques (30). Cette maladie entraînant une perte osseuse alvéolaire, et à terme une perte de dents, altère ainsi la qualité de la vie et de l'estime de soi des patients, et impose d'énormes impacts socio-économiques impliquant des coûts importants pour les systèmes de santé (31). La réalisation d'un diagnostic précoce et rapide, en complément du sondage parodontal, s'avère donc primordial.

Des auteurs ont proposé un système d'aide au diagnostic basé sur les réseaux de neurones en développant un modèle capable d'évaluer automatiquement l'atteinte parodontale d'une dent à partir de radiographies rétro-alvéolaires (32). Le statut parodontal est constitué de trois classes : sain, modérément atteint et sévèrement atteint. Le jeu de données utilisé est constitué de 1 024 dents chez 351 patients. Les prédictions du modèle, composé de 16 couches de neurones, montre que la précision varie entre 73,4 % et 82,8 % selon le groupe de dents considéré (respectivement prémolaires ou molaires). Dans ce travail néanmoins pionnier, on remarque cependant que le diagnostic est établi pour une radiographie rétro-alvéolaire et ne réalise pas l'identification précise de la dent causale. De plus, notons que les dents ayant subi un traitement endodontique, une

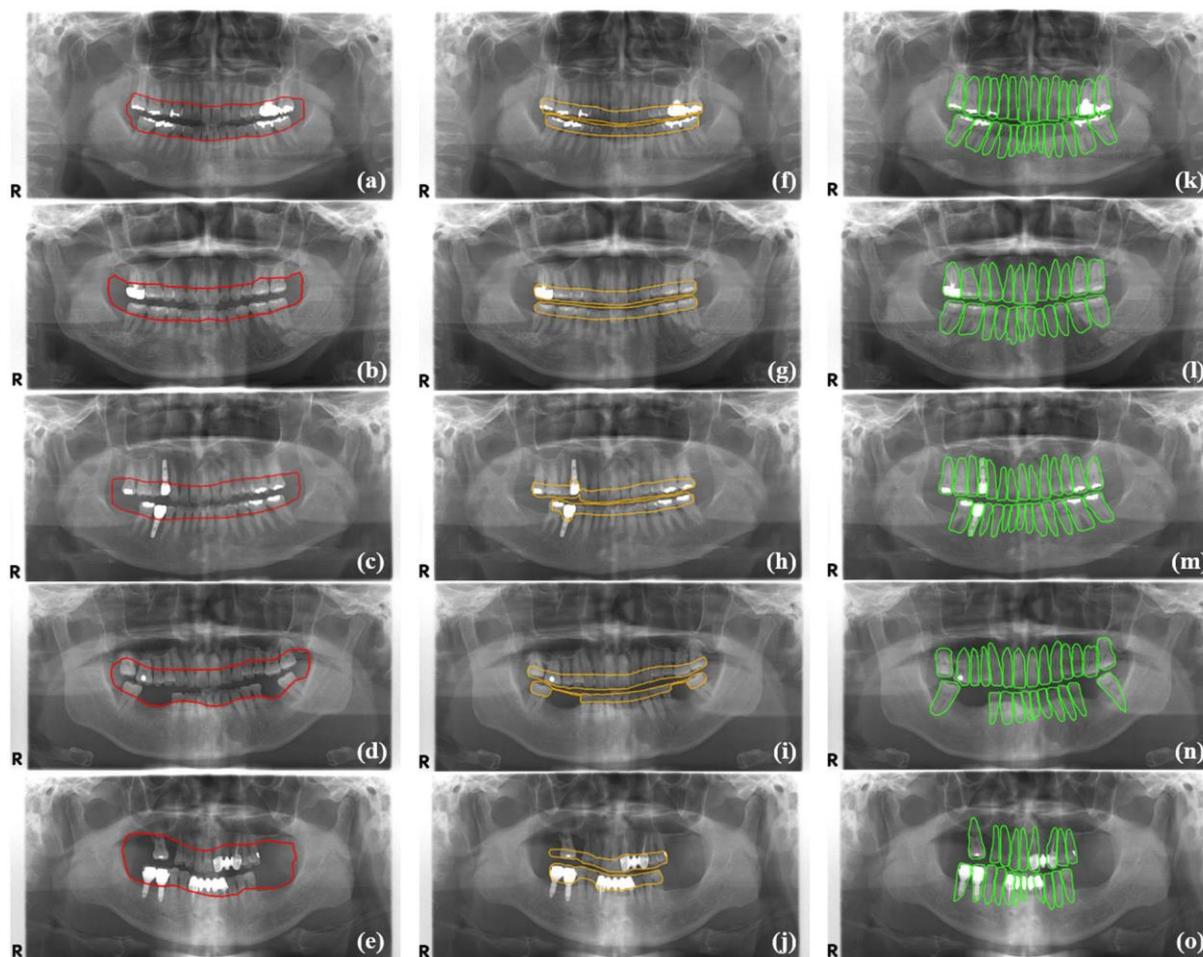
chirurgie apicale avec résection radiculaire, présentant des lésions carieuses modérées à sévères, une restauration avec une couronne périphérique complète ou encore les radiographies de faible qualité ont été exclues afin de minimiser la gestion de cas complexes, au risque cependant de s'éloigner de la réalité clinique et de limiter la généralisation des résultats de cette étude. Ce travail fournit néanmoins une première base de recherche dans l'utilisation des réseaux de neurones en parodontologie.

L'annotation automatique de régions atteintes au niveau parodontal a été poursuivie dans une perspective d'identification dans les radiographies panoramiques dentaires (33). Le modèle est composé de deux classes : on distingue les dents saines d'un point de vue parodontal et les dents avec un parodonte atteint. Le modèle est construit à partir de 100 radiographies panoramiques manuellement annotées à partir de critères à la fois cliniques et radiographiques. Le modèle développé atteint une sensibilité de 84 % et une spécificité de 88 %, fournissant un criblage relativement fiable des régions au statut parodontal défavorable, qui seront à explorer par la suite grâce à d'autres examens (radiographie rétro-alvéolaire, sondage, etc.).

En 2019, Kim et collaborateurs présentent dans leur travail un programme, *DentNet*, implémentant un réseau de neurones capable de détecter les régions avec ostéolyse sur la base de radiographies panoramiques (34). Le jeu de données est composé de 12 179 radiographies panoramiques annotées. Les auteurs stipulent que les prédictions fournies par le modèle sont supérieures à celles obtenues par des cliniciens (75 % contre 69 % respectivement). Le modèle est composé de plusieurs modèles successifs : un premier modèle extrait chacune des dents, également nommée région d'intérêt, et le second modèle est capable de classifier de façon binaire chaque région d'intérêt : présence ou absence de perte de niveau osseux.

Cependant, ces articles présentent des méthodes qui ne détectent que la région ayant perdu de l'os radiographiquement, sans permettre de préciser de façon quantitative l'alvéolyse signant la parodontite.

Ainsi, Chang et collaborateurs ont publié en 2019 une approche qui permet non seulement d'observer la perte de niveau osseux dans le cadre d'une parodontite, mais aussi de classifier automatiquement le stade de la parodontite (35). En effet, la classification des parodontites a été modifiée à plusieurs reprises pour tenter de l'aligner sur les connaissances scientifiques émergentes des dernières années. En 2017, l'Académie Américaine de Parodontologie a fourni une nouvelle définition et un nouveau cadre de classification de la parodontite sur la base de stades, notamment sur la perte de hauteur osseuse le long de la racine (36). Le niveau osseux parodontal, le niveau de jonction cémento-amélaire et les dents ont été annotés par les auteurs dans respectivement 330, 115 et 73 radiographies panoramiques, générant un jeu de données d'images où chacune de ces structures a été annotée. L'axe de la dent ou l'implant est d'abord déterminé. Deux points d'interception le long de l'axe longitudinal de la dent sont calculés au travers du niveau osseux alvéolaire et des jonctions cémento-amélaire détectés par le CNN. La distance, le long de l'axe de la dent, entre la jonction cémento-amélaire et le niveau osseux permet de classifier la maladie parodontale ou péri-implantaire (respectivement une perte d'os radiographique <15 %, comprise entre 15 % et 33 % ou supérieure à 33 %) (**Figure 7**). Le modèle génère des prédictions qui possèdent une corrélation de 0,73 avec le diagnostic posé par les experts, montrant une forte corrélation entre le diagnostic automatique et celui des experts.



**Figure 7. Résultats de détection du niveau osseux parodontal (a–e), de la jonction émail-cément (f–j), et des dents ou implants (k–o) par le réseau de neurones développé.**  
Extrait d'après Chang *et al.*, 2020 (35).

Enfin, Krois et collaborateurs ont comparé les performances d'un modèle et l'annotation d'experts dans la mesure du pourcentage de pertes osseuses parodontales (37). L'hypothèse initiale des auteurs était que leur réseau de neurones convolutifs puisse fournir, de façon significative, une meilleure annotation qu'un praticien. Cette hypothèse a été rejetée car des niveaux de précision similaires ont été obtenus avec une spécificité plus élevée mais une sensibilité plus faible que ceux des experts. De plus, les résultats mettent en évidence l'accord plutôt relatif entre les dentistes lors de la confrontation de leurs annotations.

## 4. Odontologie médico-légale

### 1. Évaluation de l'âge d'un individu

L'évaluation de l'âge d'un individu est essentiellement réalisée dans le cadre de procédures légales, surtout en cas de doute sur la majorité légale. L'âge est généralement évalué par plusieurs experts et basé sur un examen médical, impliquant une imagerie radiographique de l'os du poignet et une radiographie panoramique. Les radiographies panoramiques sont utilisées pour évaluer l'état de la minéralisation dentaire, qui est largement considéré comme le plus précis indicateur de l'âge chez les

jeunes adultes (38). L'évaluation des radiographies panoramiques est basée sur une annotation écrite qui est longue, pouvant être subjective et non reproductible entre experts.

Afin d'automatiser et de standardiser l'estimation de l'âge médico-légal, un modèle d'apprentissage automatique basé sur l'estimation de l'âge dentaire par des réseaux neuronaux convolutifs bayésiens a été développé (39). Dans ce travail, 12 000 radiographies panoramiques ont été collectées chez des patients entre 5 et 25 ans. Pour l'ensemble des radiographies à annoter, la corrélation entre l'âge prédit et l'âge réel est de 91 % mais avec une erreur moyenne de 21 mois, erreur trop importante pour retenir cette approche dans un cadre médico-légal.

Une autre approche a été de n'utiliser que la troisième molaire afin de réaliser l'estimation de l'âge d'un individu (40). Dix stades de maturation ont été considérés selon plusieurs paramètres comme le stade de minéralisation de la couronne, la formation de l'émail, la convergence de la région cervicale, la quantité de dentine apposée, la longueur radiculaire ou l'ouverture apicale. La précision moyenne obtenue s'avère être proche de 50 %, permettant d'associer la dent au bon stade. Lorsque cette dernière est mal classifiée, elle est généralement classifiée dans un stade adjacent (antérieur ou postérieur de formation).

## **2. Identification d'une personne *post-mortem***

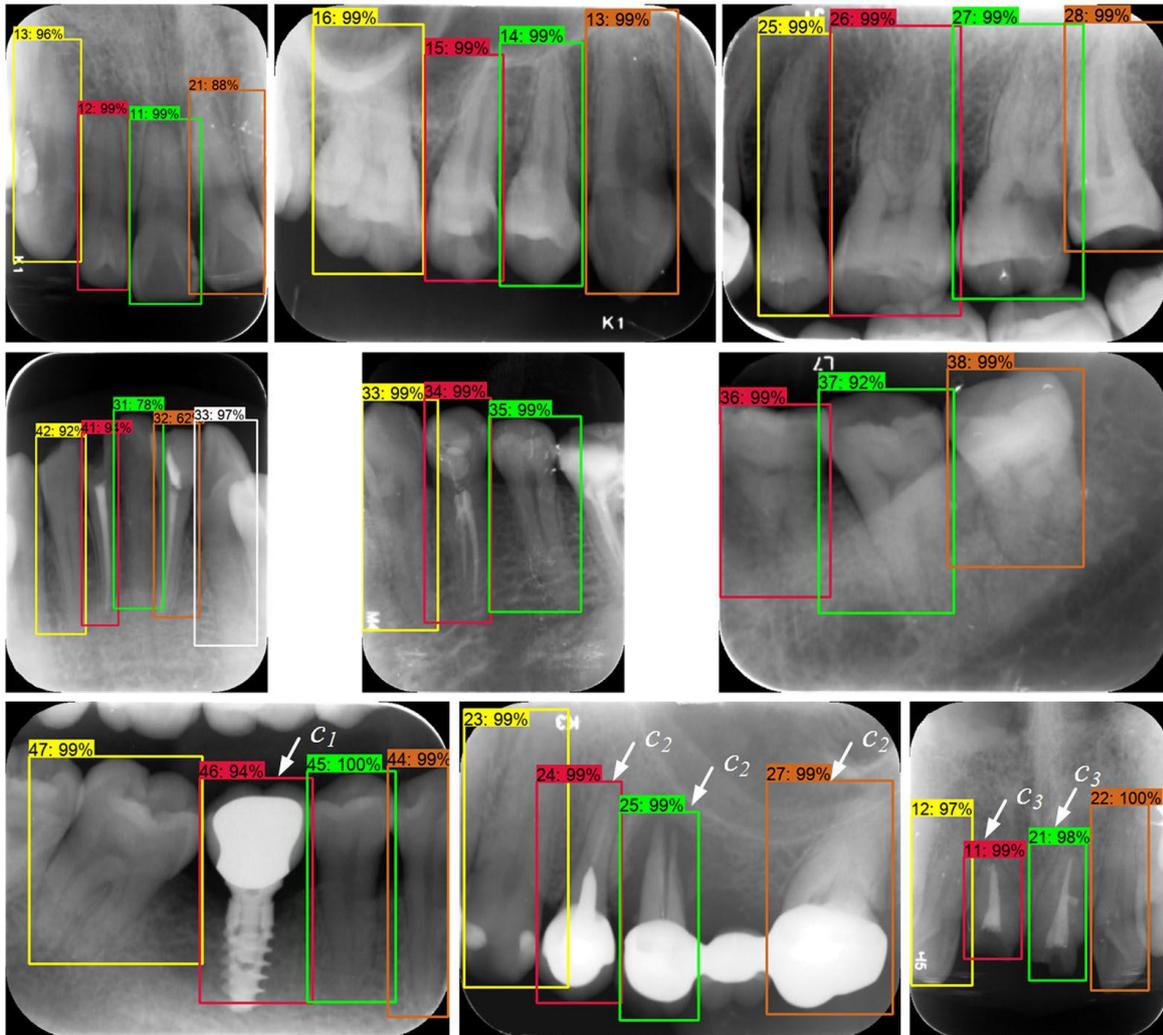
L'examen dentaire médico-légal a joué un rôle important dans l'identification d'individus, en se basant traditionnellement sur des comparaisons visuelles des dossiers dentaires ou des radiographies *ante-* et *post-mortem*.

L'objectif du travail pionnier de Matsuda et collaborateurs a été de tester l'intérêt des orthopantomographes pour réaliser l'identification des individus. Les auteurs ont utilisé des paires de radiographies réalisées sur des périodes relativement courtes et en utilisant les réseaux de neurones convolutifs (CNN) (41). Ainsi, 30 paires d'orthopantomographes obtenus à 70 jours de moyenne d'écart ont été comparées, et le modèle atteint une précision de 100 %. L'on peut néanmoins ici critiquer le faible écart temporel entre deux radiographies et l'utilisation de méthodes d'apprentissage profond sur une faible quantité de données, ce qui permet de douter de la reproductibilité des résultats.

## **3. Réalisation d'un schéma dentaire**

Dans l'optique de la réalisation d'un schéma dentaire, la détection automatique des organes dentaires s'avère être la première étape. À partir d'une radiographie panoramique, il est possible d'atteindre une sensibilité et une spécificité de plus de 99 % (42). La démarche est la suivante : la détection est réalisée à partir d'un premier modèle, puis un second modèle, composé de 32 classes, attribue à chaque dent son identifiant. Le jeu de données d'apprentissage est composé de 1 352 radiographies panoramiques. Le résultat est donc quasi identique à celui des experts, mais est en revanche bien plus rapide.

Cette méthode a été parallèlement publiée par d'autres auteurs, en étant étendue à la détection et au décompte du nombre de dents, non plus à partir de radiographies panoramiques mais à partir d'images rétro-alvéolaires (43). Les auteurs obtiennent ici une précision et une spécificité de 91 % avec un ensemble de radiographies contenant à la fois des édentements, des implants, des restaurations et des dents délabrées (**Figure 8**).



**Figure 8. Exemples d'images correctement annotées par le réseau de neurones sur des radiographies tests.**

Extrait d'après Chen *et al.*, 2019 (43).

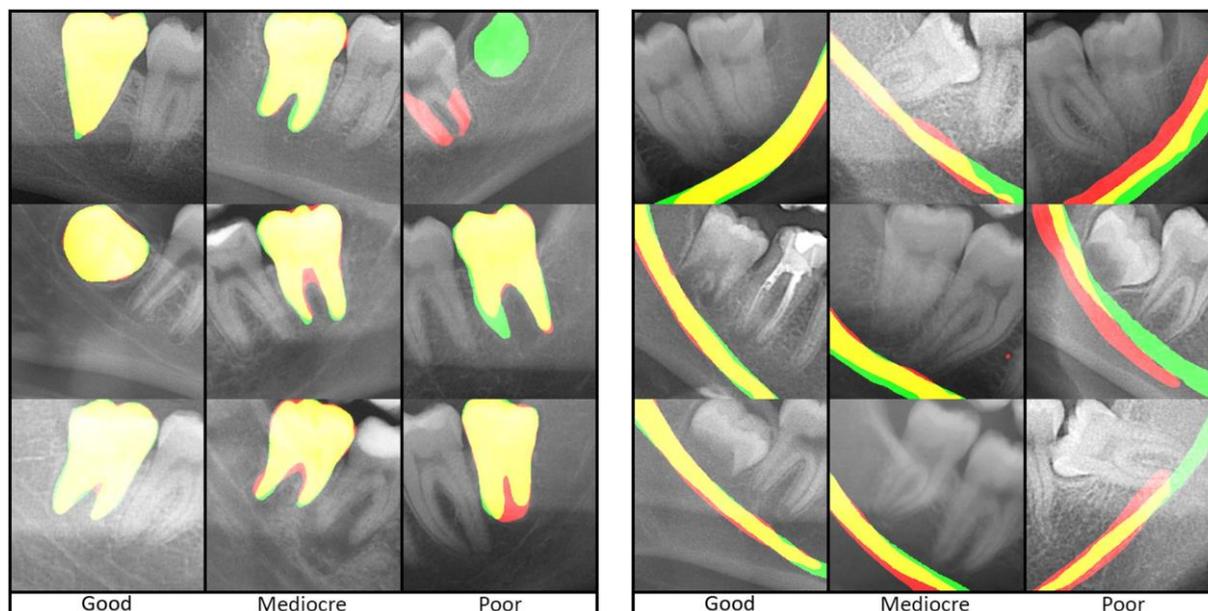
Avec de telles valeurs de précision dans l'identification des organes dentaires, il paraît désormais tout à fait envisageable de considérer l'automatisation de la création d'un schéma dentaire à partir d'une radiographie panoramique ou d'un bilan rétro-alvéolaire.

## 5. Chirurgie

Les algorithmes d'apprentissage profond sont de plus en plus appliqués dans différents domaines médicaux, principalement pour détecter et segmenter les structures anatomiques cliniquement pertinentes en vue de planification de chirurgie, afin de planifier des actes chirurgicaux ou annoter les changements pathologiques tels que des cancers (44) ; ils s'avèrent également utiles dans l'analyse automatique de lésions et de cancers en dermatologie (45). Cependant, l'application de ces méthodes en chirurgie buccale et maxillo-faciale demeure relativement rare.

Lors des actes d'avulsion de dents de sagesse, la proximité du nerf alvéolaire inférieur avec les racines des troisièmes molaires inférieures mandibulaires constitue un risque, facteur de survenue de lésions nerveuses et de troubles sensoriels ultérieurs de la lèvre inférieure et du menton. Pour

évaluer ce risque, l'identification spatiale des racines de la troisième molaire et du nerf alvéolaire inférieur sur les radiographies panoramiques est obligatoire. Dans l'étude de Vinayahalingam et collaborateurs, les auteurs ont développé et validé un système automatisé, basé sur la *deep learning*, afin de détecter et segmenter les troisièmes molaires et le nerf alvéolaire inférieur à partir de radiographies panoramiques (46).



**Figure 9. Comparaison des segmentations automatiques et manuelles des troisièmes molaires mandibulaires et du nerf alvéolaire inférieur.**

Vert : segmentation manuelle de l'expert ; rouge : segmentation automatique du réseau de neurones ; jaune : chevauchement entre la segmentation automatique et manuelle.

Extrait d'après Vinayahalingam *et al.*, 2019 (46).

Bien que les résultats ne soient ici pas toujours reproductibles et qu'aucun score de risque ne soit fourni à la suite de la segmentation, ce travail demeure pionnier dans l'annotation d'éléments anatomiques dans la sphère oro-faciale (**Figure 9**).

**Tableau 1. Résumé des applications cliniques, des données et des performances des systèmes d'analyse automatique d'images en odontologie dans la littérature.**

Les éléments du tableau sont colorés en fonction de la spécialité considérée en odontologie : le champ médico-légal en vert, la parodontologie en bleu, l'odontologie conservatrice en rouge, la chirurgie en gris.

Article	Objectif	Jeu de données	Méthode	Performances
(42) Tuzof <i>et al.</i> , 2019	Détection dentaire	1 352 radiographies panoramiques	Fast R-CNN	0.99 précision et sensibilité
(43) Chen <i>et al.</i> , 2019	Détection dentaire	850 radiographies rétro-alvéolaires	Fast R-CNN	0.91 précision et sensibilité
(39) de Back <i>et al.</i> , 2019	Estimation de l'âge médico-légal	12 000 radiographies panoramiques	CNN Bayésien	Erreur moyenne de 21 mois
(40) de Tobel <i>et al.</i> , 2017	Estimation de l'âge médico-légal par stade de la troisième molaire mandibulaire	400 radiographies panoramiques	CNN	Précision de 0.51 dans la classification dans une classe d'âge
(41) Matsuda <i>et al.</i> ,	Identification	30 radiographies	CNN	

2020	d'individus	panoramiques		
(32) Lee <i>et al.</i> , 2018	Prédiction de l'atteinte parodontale d'une dent	1 044 dents radiographiées	CNN	Précision de 0.81
(33) Thanathornwong <i>et al.</i> , 2020	Identification d'une dent au parodonte atteint	100 radiographies panoramiques	Faster R-CNN	Sensibilité 0.84 Spécificité 0.88 F1 score de 0.81
(34) Kim <i>et al.</i> , 2019	Détection de perte osseuse parodontale	12 179 radiographies panoramiques	Mask R-CNN	Sensibilité 0.71 Spécificité 0.73 F1 score 0.75
(35) Chang <i>et al.</i> , 2020	Détection et diagnostic de perte osseuse parodontale	518 radiographies panoramiques	Mask R-CNN	Précision du niveau osseux 0.92 Prédiction de la dent 0.87
(37) Krois <i>et al.</i> , 2019	Détection de perte osseuse parodontale	2 001 radiographies panoramiques	CNN	Sensibilité 0.81 Spécificité 0.81
(24) Srivastava <i>et al.</i> , 2017	Détection et diagnostic des caries dentaires	3 000 radiographies rétro-coronaires	CNN	Sensibilité 0.80 Précision 0.61 F1 score 0.70
(26) Lee <i>et al.</i> , 2018	Détection et diagnostic des caries dentaires	3 000 radiographies rétro-alvéolaires	CNN	Précision 0.88
(28) Ekert <i>et al.</i> , 2019	Détection des lésions péri-apicales	2 001 dents segmentées à partir de 85 radiographies panoramiques	Mask R-CNN	Sensibilité 0.65 Spécificité 0.87
(27) Cantu <i>et al.</i> , 2020	Détection et diagnostic des caries dentaires	3 293 radiographies rétro-coronaires	Mask R-CNN	Sensibilité 0.75 Précision 0.80 F1 score 0.73
(46) Vinayahalingam <i>et al.</i> , 2019	Annotation du nerf alvéolaire inférieur	81 radiographies panoramiques	CNN	Inconnues

Dans toutes les études, les réseaux de neurones ont été utilisés comme formalisme de modélisation (**Tableau 1**), dans différentes déclinaisons tels que les *R-CNN*, *Fast R-CNN* ou *Mask R-CNN*. Les articles basés sur les réseaux de neurones sont apparus dans le domaine de l'odontologie depuis 2016, et par la suite, un nombre exponentiel d'articles utilisant les CNN en odontologie ont été publiés comme déjà montré en **Figure 1**. Enfin, l'on remarque que la quantité de données nécessaires dans le but d'obtenir un apprentissage de qualité du modèle se situe généralement aux environs de plusieurs milliers de clichés annotés.

## 4. Développement d'un système d'annotation automatique des radiographies dentaires

### 1. Objectif

L'objectif de ce travail était d'essayer de développer les bases d'un système d'annotation de radiographies rétro-alvéolaires. En effet, en considérant la littérature publiée à ce jour, l'on ne trouve pas de publication traitant de la détection des soins dentaires dans l'objectif de générer un schéma dentaire.

Pour réaliser ce travail, il a tout d'abord été nécessaire de trouver un formalisme de modélisation s'adaptant naturellement à la classification d'images. Au vu de l'analyse de la littérature effectuée précédemment, il apparaît que les réseaux de neurones convolutifs sont bien adaptés à l'analyse d'images. Ensuite, l'idée de ce travail n'est pas de réaliser un logiciel offrant toutes les possibilités d'annotation d'une image avec d'excellentes performances, mais plutôt de proposer une démarche et de poser les bases d'un système d'analyse qui pourra ensuite être optimisé, notamment par l'obtention d'une quantité de données d'apprentissage annotées plus importante ou par l'utilisation d'algorithmes de détection plus récents et performants.

### 2. Collection du jeu de données

Afin de constituer le jeu d'apprentissage du modèle, les bilans radiographiques rétro-alvéolaires de 106 patients ont été extraits de la base de donnée DBSWin du Centre de Soins Dentaires du CHU de Nantes.

Seules les radiographies de bonne qualité, centrées, non floutées, avec un contraste et une luminosité correctement ajustés et sans chevauchement des dents ont été conservées pour constituer le jeu de données.

### 3. Annotation du jeu de données

Au total, 2 090 dents ont été annotées (**Tableau 2**). Selon la nature du soin réalisé, six classes ont été définies : on distingue les dents ne présentant pas de restauration, avec un ou plusieurs soins d'odontologie conservatrice, avec traitement endodontique, avec couronne, avec restauration endodontique et couronne, et enfin les implants. L'annotation va être contenue dans le nom du fichier et elle est la suivante :

- un identifiant patient unique (exemple AA pour patient 1, AB pour patient 2, etc., afin de rendre anonymes les données et de ne pas avoir de redondance dans le nom de fichier),
- le numéro de la dent,
- la classe de dent (I pour incisive, C pour canine, PM pour prémolaire et M pour molaire),
- la classe de restauration (S pour sans restauration, C pour couronne, T pour traitement endodontique, I pour implant, A pour restauration).

Par exemple, le fichier AC\_36\_M\_CT.jpg désigne une image contenant une première molaire mandibulaire dépulpée et couronnée.

Tableau 2. Jeu de données obtenu suite à la phase d'annotation des images radiographiques.

Sans soin	Traitement endodontique	Couronne	Couronne et traitement endodontique	Soin OC	Implants
1 307	68	33	338	336	8

Face au faible nombre d'images d'implants, de couronnes et de traitements endodontiques seuls, ces dernières classes n'ont pas été retenues pour construire le classifieur. Le modèle est donc constitué de trois classes : « dent non restaurée », « dent restaurée par soin OC » et « dent couronnée et dépulpée ». Un script Python a été développé pour classer les images annotées dans différents répertoires.

#### 4. Augmentation du jeu de données

Afin d'accroître la taille du jeu de données et obtenir davantage d'images d'apprentissage, des images ont été générées à partir des images collectées précédemment : il s'agit de l'augmentation du jeu de données. Des mouvements de décalage, de symétrie, de rotation et enfin de zoom sont appliqués. Cela a pour effet de généraliser le modèle à des images non présentes dans l'ensemble d'images issues des données initiales. Un script Python a été réalisé afin d'automatiser cette étape. Un exemple est présenté en **Figure 10**.

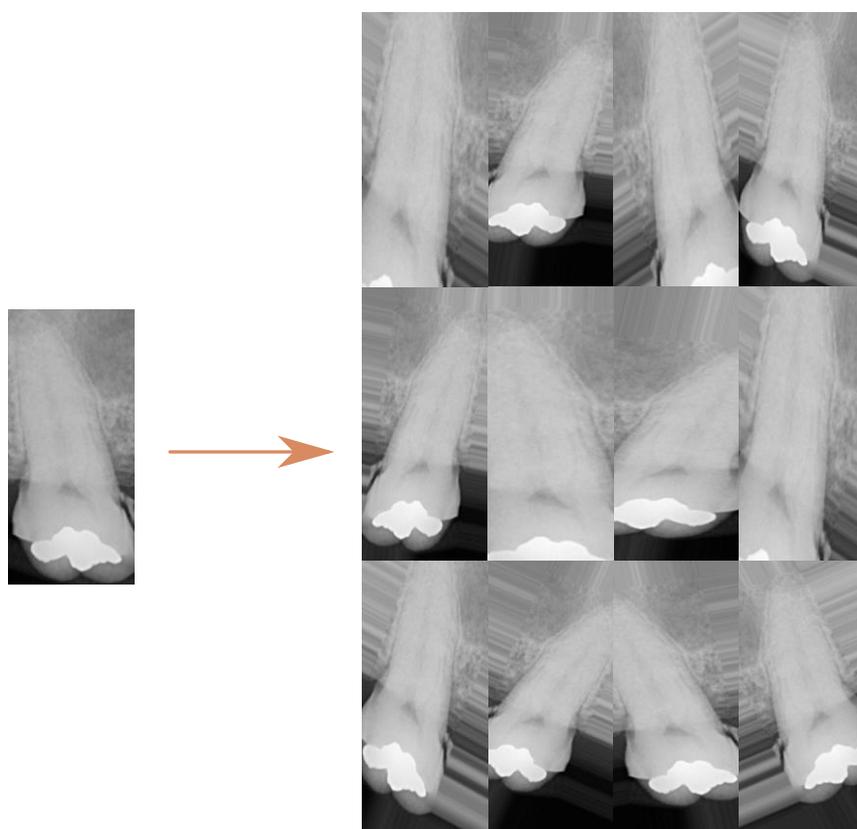


Figure 10. Exemple de l'utilisation de l'augmentation du jeu de données à partir d'une image. Des mouvements de transformation, de zoom, de translation horizontale et de rotation sont réalisés.

La quantité de données utilisées pour l'apprentissage du modèle est résumée dans le **tableau 3**.

**Tableau 3. Nombre d'images utilisées pour chacune des trois classes « dent non restaurée », « dent restaurée par soin OC » et « dent couronnée et dépulpée ».**

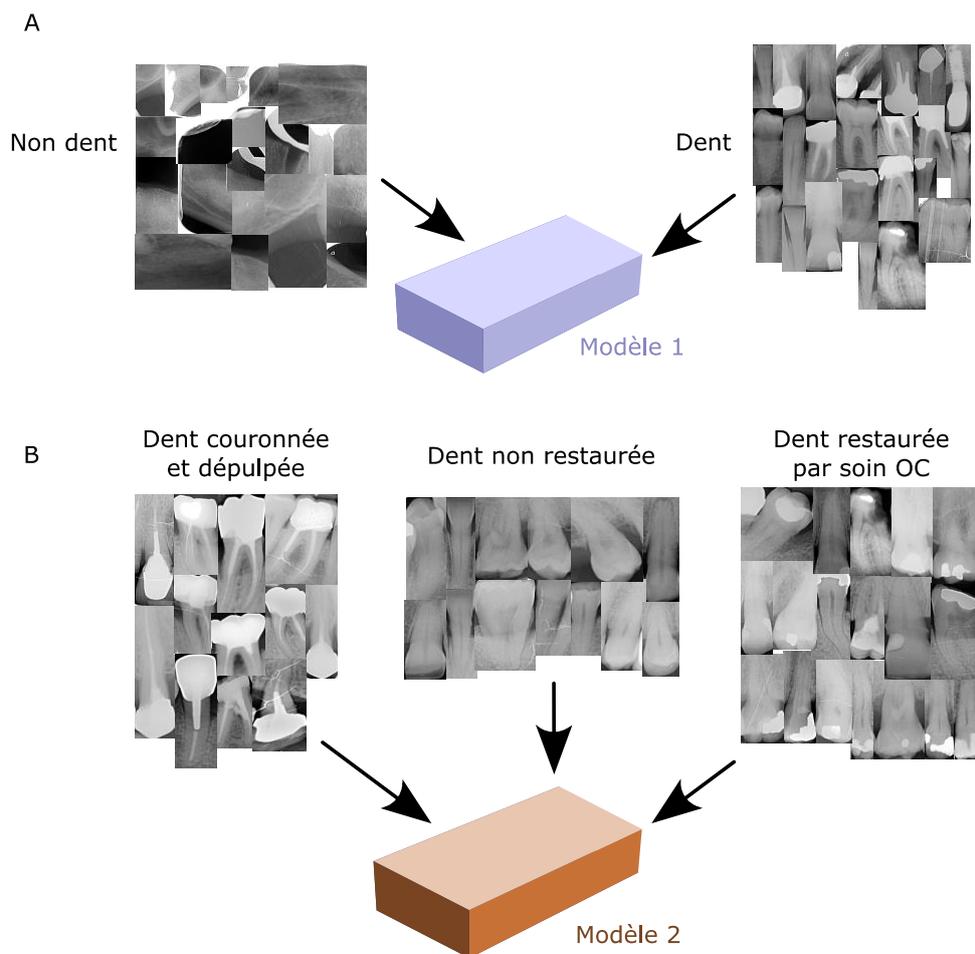
Dent non restaurée	Dent restaurée par soin OC	Couronne et dépulpée
2 525	2 417	2 446

## 5. Modèles de réseaux de neurones de convolution

Nous avons développé deux modèles basés sur les réseaux de neurones convolutifs afin de réaliser l'identification et la classification automatiques des organes dentaires.

Le premier modèle va pouvoir classer une image dans la classe « dent » ou dans la classe « non-dent ». Un réseau de neurones convolutifs de type MobileNetV2 (47), offrant de bonnes performances avec un coût computationnel acceptable, a été utilisé.

Le second modèle sert à différencier les classes « dent non restaurée », « dent restaurée par soin OC » et « dent couronnée et dépulpée » afin de classer les dents annotées par le premier modèle. L'architecture du modèle est un réseau de neurones de type VGGNet (48), composé de cinq couches superposées de convolution associées à des couches de regroupement (*pooling*), afin de diminuer la taille des données traitées. Cette architecture offre de bons résultats en matière de classification.



**Figure 11. Pipeline montrant les données utilisées pour l'apprentissage des deux modèles.**

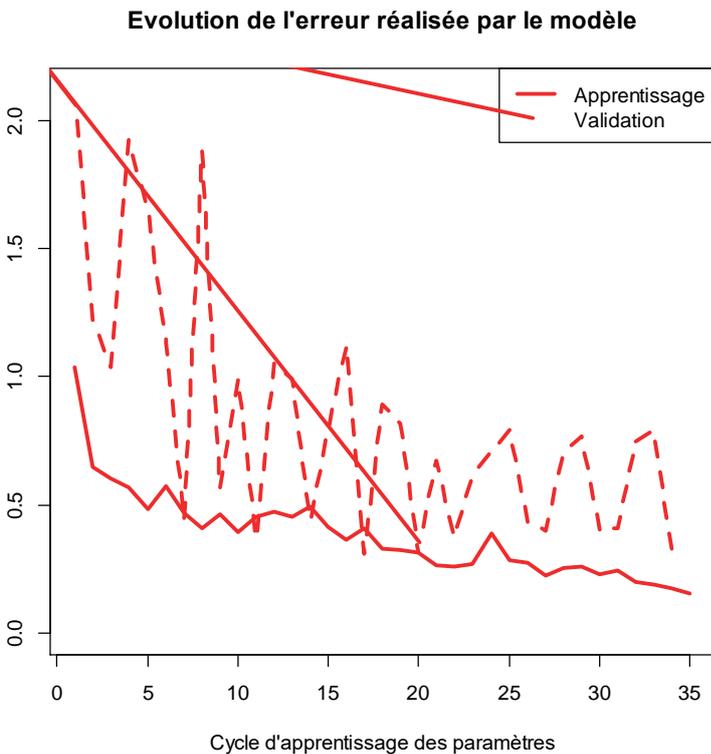
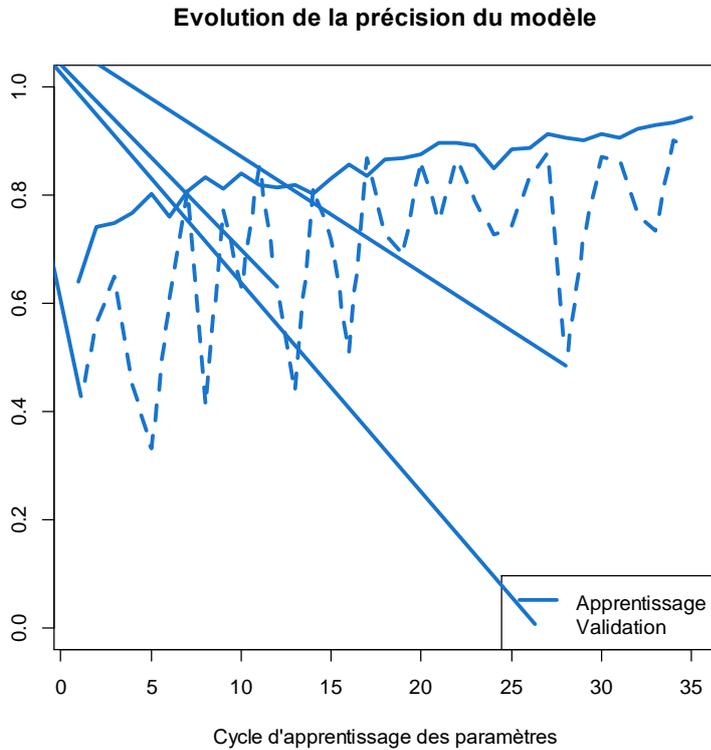
(A) Le modèle 1 est utilisé pour différencier une dent sur une image de ce qui n'est pas une dent. (B) Le modèle 2 est utilisé pour différencier les trois classes de dents à annoter.

Les éléments annotés en tant que « dent » par le premier modèle sont ensuite transmis au second modèle, qui apportera alors une classification précisant le type de restauration sur la dent identifiée par le premier modèle (**Figure 11**).

Pour coder les réseaux de neurones, des scripts ont été développés en utilisant toujours le langage de programmation Python, notamment à partir des bibliothèques TensorFlow (49) et Keras (50).

## 6. Apprentissage des paramètres du modèle

Une fois les modèles construits, l'apprentissage des paramètres de l'ensemble des filtres de convolution est réalisé, et les performances de ces derniers peuvent être examinées (**Figure 12**).



**Figure 12. Graphique représentant l'évolution de la précision et de l'erreur du modèle au cours des cycles d'apprentissage.**

En haut, est présentée l'évolution de la précision du modèle sur les données d'apprentissage en traits pleins et sur les données de validation en traits discontinus. En bas, est présentée l'évolution de l'erreur du modèle sur les données d'apprentissage en traits pleins et sur les données de validation en traits discontinus.

En **Figure 12**, on peut observer qu'au fur et à mesure des cycles d'optimisation des paramètres du modèle, la précision de celui-ci augmente et les erreurs de prédiction diminuent. Une validation croisée est effectuée pendant la phase d'entraînement du modèle ; ainsi, à chaque itération, 80 %

des données sont utilisées pour l'apprentissage et 20 % pour la validation, afin d'évaluer simultanément la performance du modèle. On remarque que la qualité des prédictions entre données d'apprentissage et de validation est relativement congruente, ce qui signifie qu'il y a peu de sur-apprentissage du modèle car le modèle ne prédit guère mieux les données d'apprentissage que les données de validation à l'issue de l'estimation des paramètres. Autrement dit, les prédictions du modèle sont généralisables de façon fiable à des données qui n'ont jamais été vues par le modèle lors de l'apprentissage. L'apprentissage du modèle est ensuite stoppé dès lors que la précision de la prédiction sur les données de validation cesse de s'améliorer.

## 7. Évaluation des performances des modèles de classification

Les performances de classification des modèles ont été évaluées par validation croisée. Le principe de la validation croisée est de diviser le jeu d'apprentissage en deux sous-groupes : une partie est dédiée à l'apprentissage et l'autre partie est utilisée comme évaluation. Ici, 80 % des données sont utilisées comme apprentissage et 20 % comme évaluation des modèles.

Les résultats de la validation croisée sont présentés en **tableau 4** et **tableau 5**.

**Tableau 4. Performance du modèle classifiant « dent » et « non-dent ».**

	Précision	Sensibilité	F1-score
Non-dent	0.54	0.99	0.70
Dent	1.00	0.69	0.82

**Tableau 5. Performance du modèle classifiant « dent non restaurée », « dent restaurée par soin OC » et « dent couronnée et dépulpée ».**

	Précision	Sensibilité	F1-score
Dent couronnée et dépulpée	0.95	0.98	0.96
Dent non restaurée	0.86	0.88	0.87
Dent restaurée par soin OC	0.87	0.83	0.85

Pour le premier modèle, les performances obtenues sont relativement correctes ; la précision pour la détection de la classe « dent » est excellente signifie qu'il n'y a pas de faux positifs prédits pour cette classe.

Le modèle réalisant la classification des trois classes de dents produit des résultats encore plus satisfaisants. Les meilleurs résultats sont obtenus pour les dents couronnées et dépulpées, pour lesquelles la précision et la sensibilité s'avèrent excellentes.

## 8. Détection des dents

L'algorithme *selective search* est utilisé afin de segmenter l'image en régions d'intérêt (51). Afin de grouper les pixels similaires, cet algorithme utilise plusieurs critères pour réaliser la segmentation de l'image : la similarité de couleur, la similarité de texture, la similarité par taille et enfin la similarité de

contour. Une fonction vient finalement intégrer l'ensemble de ces paramètres afin d'effectuer le groupement des pixels similaires.

Il est important de préciser que l'algorithme de recherche sélective ne donne pas de prédictions de classe : ce sera le rôle du classificateur. C'est pour cette raison qu'un réseau de neurones convolutifs classifiant les images en deux classes a été développé : le modèle différenciant une classe « dent » et une classe « non-dent » annotera les propositions de l'algorithme *selective search*.

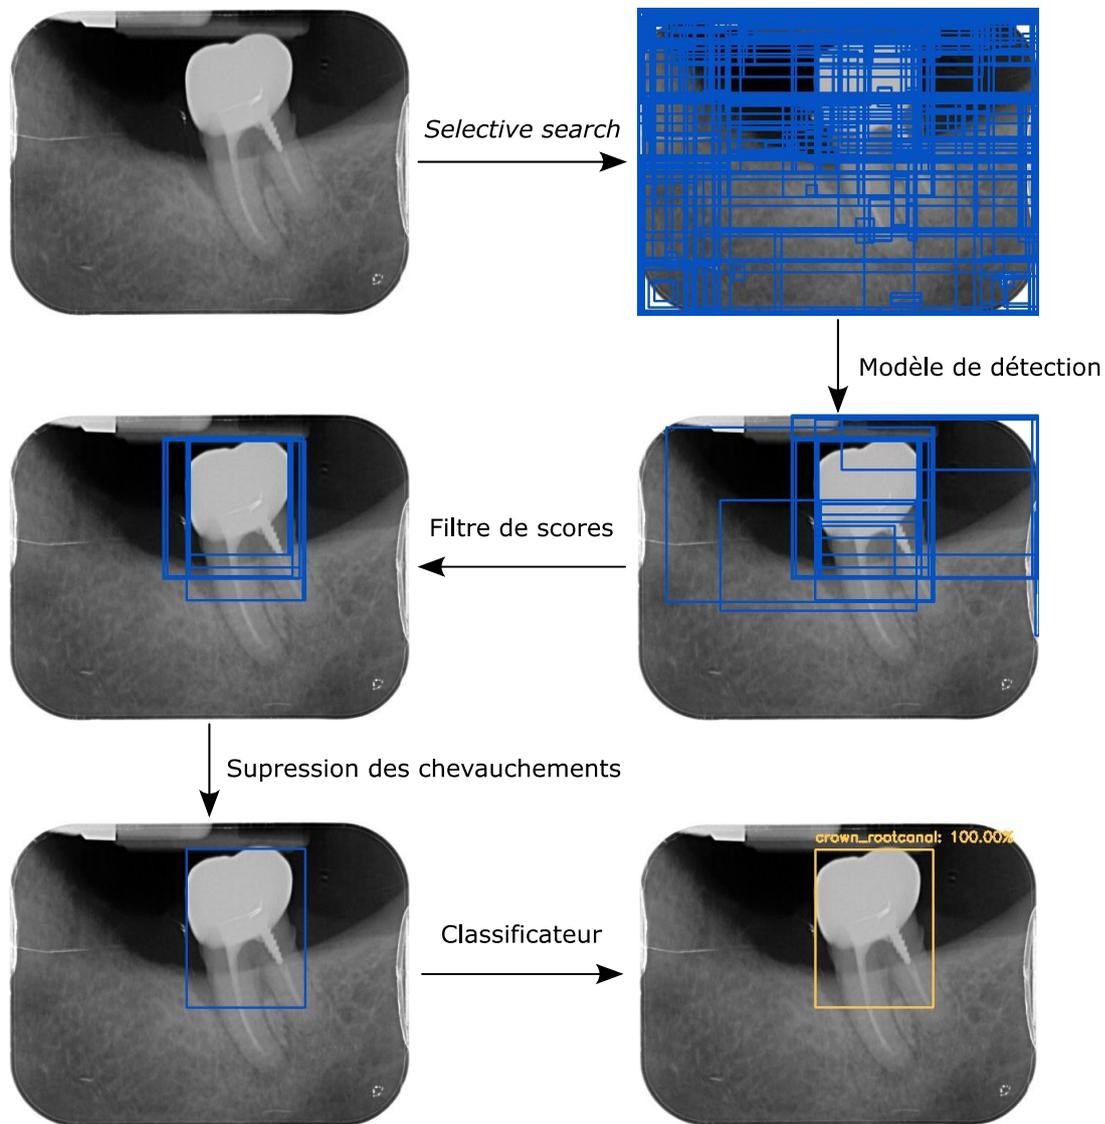
## 9. Identification et classification des dents.

La **Figure 13** présente un exemple de détection et de classification par étape d'une dent isolée. On peut ici apprécier la façon dont les régions d'intérêt sélectionnées par l'algorithme *selective search* sont raffinées successivement à chaque étape, jusqu'à sélectionner la région unique correspondant à la structure dentaire. Le premier modèle discriminant entre une image de « dent » et une image « non-dent » est d'abord appliqué. Afin de limiter les faux positifs au minimum, un filtre est appliqué sur les scores en ne sélectionnant que les prédictions dont les probabilités sont supérieures à 0,95.

Ensuite, un problème lié à l'algorithme *selective search* est qu'il détecte quasi systématiquement plusieurs fois une dent dans des cadrages différents. Il est donc nécessaire d'unifier l'ensemble des prédictions se chevauchant, et donc de permettre qu'une dent ne soit détectée qu'une seule fois. Ainsi, si deux prédictions sont superposées à plus de 20 %, seule l'image avec l'aire la plus importante sera conservée.

L'ensemble des organes dentaires alors annotés peuvent être classifiés par le second modèle discriminant entre les différents types de reconstitutions sélectionnés au départ.

L'ensemble de ces étapes a été codé dans un script qui utilise en entrée l'image que l'on souhaite annoter, ainsi que les deux modèles de réseaux de neurones convolutifs. En sortie, le script fournit l'image annotée composée de boîtes désignant la région détectée, la nature de la classe et la probabilité associée.



**Figure 13. Pipeline développant l'ensemble des étapes d'annotation de la méthode développée et appliquée à une radiographie rétro-alvéolaire.**

Sur la radiographie originale est d'abord appliqué l'algorithme *selective search* afin d'identifier les régions d'intérêt. Le classificateur est appliqué sur l'ensemble de ces boîtes pour sélectionner celles correspondant à la classe « dent ». Un filtre sur les scores est appliqué. Les chevauchements sont supprimés. Le classificateur permettant de déterminer à quelle classe appartient cette dent est finalement appliqué.

## 10. Présentation des résultats de prédictions sur des radiographies dentaires

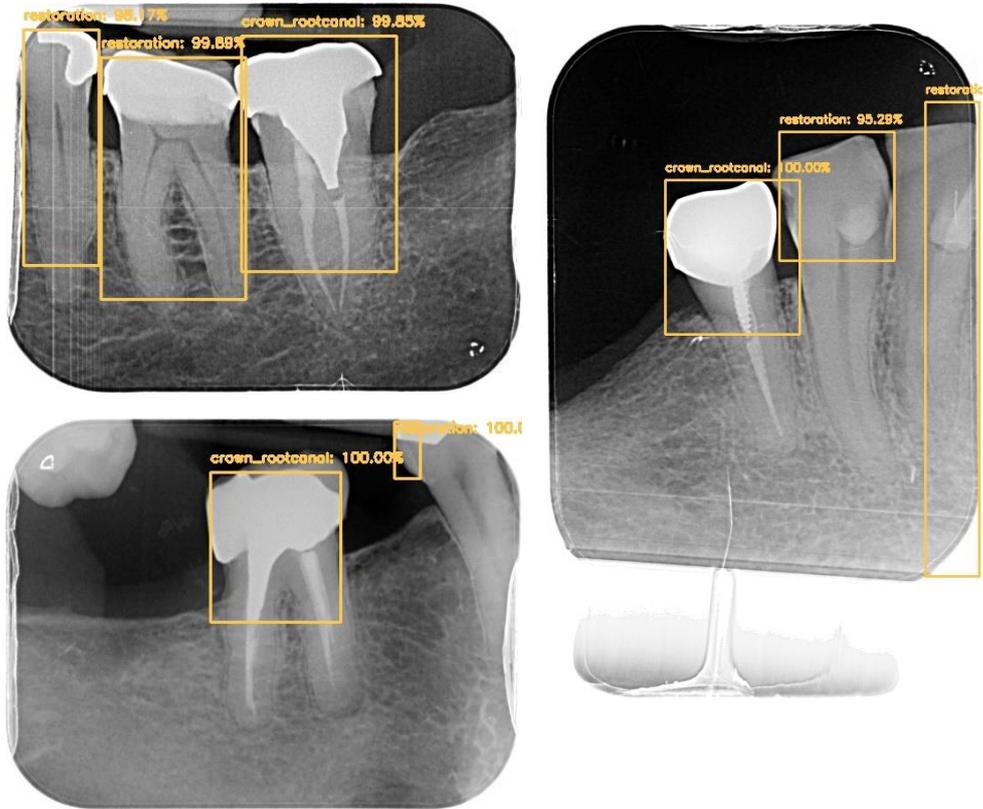


Figure 14. Exemples d'annotations correctes réalisées par le modèle.

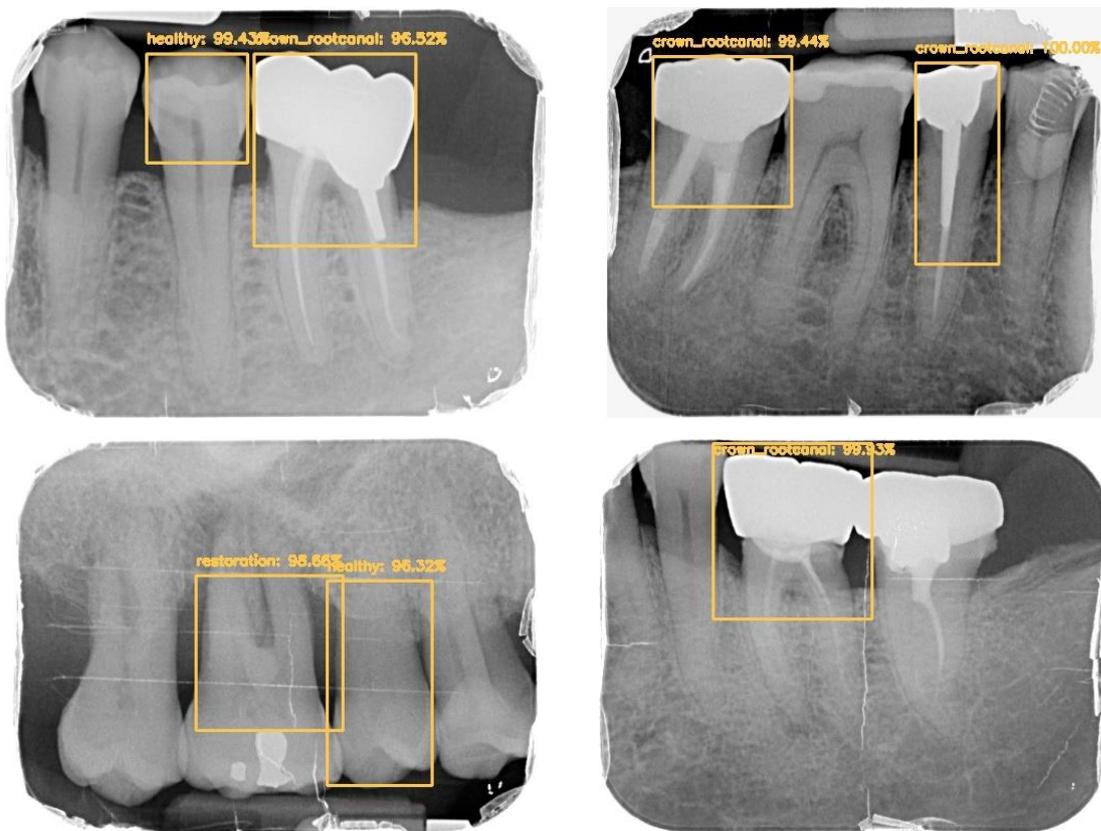
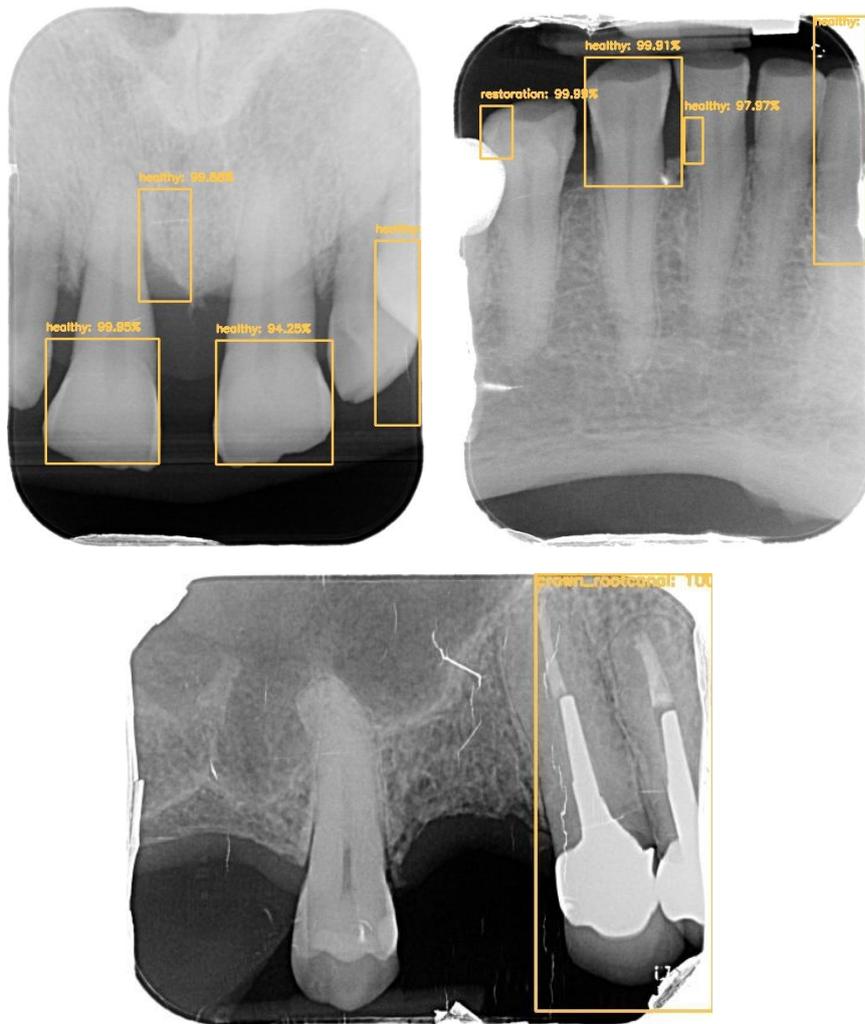


Figure 15. Exemples d'éléments non annotés par le modèle développé.



**Figure 16. Exemples d’annotations incorrectes par le modèle.**

Le script permettant d’utiliser les modèles générés précédemment et de réaliser les prédictions a été utilisé sur plusieurs radiographies rétro-alvéolaires ; plusieurs exemples sont présentés en **Figure 14, 15 et 16**. Bien que nous réalisions des prédictions entièrement correctes en matière d’identification et de classification sur plusieurs radiographies, l’on retrouve un certain nombre de cas où les prédictions s’avèrent inexactes. Les erreurs de prédiction sont majoritairement liées à des organes dentaires non annotés, autrement dit des faux négatifs dus à une sensibilité insuffisante du modèle. Des faux positifs sont également retrouvés et non présentés ici. Enfin, il existe un certain nombre de cas où l’organe dentaire est détecté mais où la classe associée à celui-ci est erronée.

Les méthodes d’apprentissage en profondeur peuvent parfois être considérées comme une « boîte noire » car l’on ne peut pas expliquer intuitivement comment les prédictions sont faites par l’algorithme ni pourquoi une prédiction va, par exemple, être correcte sur une première image et erronée sur une seconde alors que peu de différences sont perceptibles à l’œil. Il est donc crucial de rester critique face aux résultats apportés par un modèle et d’en évaluer les performances sur de nombreuses données de tests.

## 11. Perspectives

En termes de perspectives de travail, il serait souhaitable d'augmenter la taille du jeu de données. La quantité de celles-ci n'est pas réellement le facteur limitant dans l'analyse d'images en odontologie car il s'agit d'un examen routinier, mais c'est bien l'annotation des données qui est l'élément le plus chronophage dans la conception d'un modèle d'analyse d'images.

Dans l'optique de la réalisation d'un schéma dentaire automatisé, un modèle annotant également le numéro de la dent, soit un modèle composé de 32 classes, devrait être inclus dans la procédure comme le propose le travail réalisé par Chen et collaborateurs (43), afin d'associer à la fois une restauration et un numéro de dent à chaque objet détecté.

De plus, utiliser des algorithmes plus récents et plus rapides tels que le *Faster R-CNN* permettrait probablement d'augmenter la qualité et la vitesse de la détection. Avec une quantité de données plus importante, d'autres classes pourraient être ajoutées au modèle, comme les implants ou les pontiques de bridges, afin d'être plus exhaustif dans la diversité d'éléments annotés. Il serait finalement intéressant de pouvoir différencier une dent délabrée d'une dent saine dans l'établissement d'un schéma dentaire, ce qui ouvrirait alors une voie vers la dimension diagnostic de l'analyse automatique d'images.

## 5. Conclusion

L'analyse de films radiographiques dentaires occupe une part importante du temps de travail du chirurgien-dentiste, et des erreurs d'analyse peuvent parfois conduire à un sous-diagnostic ou à un diagnostic erroné. Les erreurs de diagnostic peuvent être réduites si des outils d'aide à l'interprétation des images radiographiques sont développés pour, à défaut d'améliorer la qualité, accélérer la rapidité du diagnostic. L'identification automatique des dents à l'aide de films numérisés pourrait donc constituer une assistance importante pour contribuer à augmenter la qualité des soins prodigués.

Comme le mentionnent Schwendicke *et al.*, (13), il est pour l'instant difficile à dire si l'évaluation d'une image radiographique par des réseaux de neurones convolutifs est plus ou moins précise que l'évaluation par un dentiste. En effet, les données d'apprentissages du réseau et les données tests utilisées pour comparer les performances du modèle à celles des experts sont très souvent annotées par les mêmes personnes. Dans ce cas, il est normal que la performance de l'évaluateur demeure supérieure à celle du modèle.

Par ailleurs, l'on remarque qu'il n'existe pas de partage des jeux de données lors des publications ni même des programmes aboutissant aux prédictions. Bien que la sécurité des données des patients ainsi que les perspectives économiques de tels modèles puissent justifier respectivement ces deux éléments, l'on peut supposer que cela ne ralentira pas l'essor de la recherche et de la mise en pratique de l'analyse d'images automatiques en odontologie.

De plus, dans le domaine médical, l'on ne retrouve pas de jeux de données de référence permettant de comparer différents modèles, contrairement aux bases d'images généralistes comme *ImageNet* (52) ou *COCO* (53) contenant plus de 2,5 millions d'objets annotés dans 300 000 images servant de référence dans la comparaison de performance d'algorithmes en analyse d'images. La création de grandes bases de données d'images médicales anonymes pourrait dynamiser la comparaison de méthodes dans la recherche des algorithmes les plus performants.

La réalisation d'un schéma dentaire initial ou odontogramme est obligatoire avant de débiter les soins dentaires. Cette annotation manuelle dans le logiciel dédié s'avère néanmoins être un acte fastidieux. Le développement d'une passerelle informatique permettant de traduire automatiquement l'information contenue dans un bilan radiographique sous la forme d'un schéma dentaire s'avère donc tout à fait pertinente.

## 6. Bibliographie

1. Lee J-G, Jun S, Cho Y-W, Lee H, Kim GB, Seo JB, et al. Deep learning in medical imaging: general overview. *Korean J Radiol.* août 2017;18(4):570-84.
2. Lundervold AS, Lundervold A. An overview of deep learning in medical imaging focusing on MRI. *Z Für Med Phys.* 1 mai 2019;29(2):102-27.
3. Zhou SK, Greenspan H, Davatzikos C, Duncan JS, van Ginneken B, Madabhushi A, et al. A review of deep learning in medical imaging: Image traits, technology trends, case studies with progress highlights, and future promises. arXiv:200809104 [Internet]. août 2020; Disponible sur: <http://arxiv.org/abs/pdf/2008.09104.pdf>
4. McCarthy J. Artificial intelligence, logic and formalizing common Sense. In: Thomason RH, éditeur. *Philosophical logic and artificial intelligence.* Ville ? : Springer; 1989:. p. 161-90.
5. Das S, Dey A, Pal A, Roy N. Applications of artificial intelligence in machine learning: review and prospect. *Int J Comput Appl.* avr 2015;115(9):31-41.
6. Graves A, Mohamed A, Hinton G. Speech recognition with deep recurrent neural networks. In: 2013 IEEE International Conference on Acoustics, Speech and Signal Processing, Vancouver Canada, 26-31 mai 2013: p. 6645-9.
7. LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature.* mai 2015;521(7553):436-44.
8. Jiang T, Gradus JL, Rosellini AJ. Supervised machine learning: a brief primer. *Behav Ther.* 1 sept 2020;51(5):675-87.
9. Chan S, Siegel EL. Will machine learning end the viability of radiology as a thriving medical specialty? *Br J Radiol.* févr 2019;92(1094): p?
10. Hosny A, Parmar C, Quackenbush J, Schwartz LH, Aerts HJWL. Artificial intelligence in radiology. *Nat Rev Cancer.* août 2018;18(8):500-10.
11. Hopfield JJ. Neural networks and physical systems with emergent collective computational abilities. *Proc Natl Acad Sci U S A.* avr 1982;79(8):2554-8.
12. Litjens G, Kooi T, Bejnordi BE, Setio AAA, Ciompi F, Ghafoorian M, et al. A survey on deep learning in medical image analysis. *Med Image Anal.* déc 2017;42:60-88.
13. Schwendicke F, Golla T, Dreher M, Krois J. Convolutional neural networks for dental image diagnostics: A scoping review. *J Dent.* déc 2019;91:103226.
14. Albawi S, Mohammed TA, Al-Zawi S. Understanding of a convolutional neural network. In: 2017 International Conference on Engineering and Technology (ICET), Akdeniz University, Antalya Turkey, 21-23 august 2017: . p. 1-6.
15. Gu J, Wang Z, Kuen J, Ma L, Shahroudy A, Shuai B, et al. Recent advances in convolutional neural networks. *Pattern Recognit.* mai 2018;77:354-77.

16. Girshick R, Donahue J, Darrell T, Malik J. Rich feature hierarchies for accurate object detection and semantic segmentation. In: 2014 IEEE Conference on Computer Vision and Pattern Recognition, Columbus USA, 23-28 june 2014: p. 580-7.
17. Ren S, He K, Girshick R, Sun J. Faster R-CNN: Towards real-time object detection with region proposal networks. *IEEE Trans Pattern Anal Mach Intell.* juin 2017;39(6):1137-49.
18. He K, Gkioxari G, Dollár P, Girshick R. Mask R-CNN. In: 2017 IEEE International Conference on Computer Vision (ICCV), Venice Italy, 22-29 october 2017: p. 2980-8.
19. Liu W, Anguelov D, Erhan D, Szegedy C, Reed S, Fu C-Y, et al. SSD: Single Shot MultiBox Detector. In: Leibe B, Matas J, Sebe N, Welling M, éditeurs. *Computer Vision – ECCV 2016.* Ville ? : Springer International Publishing; 2016:. p. 21-37.
20. Redmon J, Divvala S, Girshick R, Farhadi A. You only look once: unified, real-time object detection. In: 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las vegas USA, 26 june - 1<sup>st</sup> july 2016: p. 779-88.
21. Langland OE, Langlais RP, Preece JW. *Principles of dental imaging.* Ville ? : Lippincott Williams & Wilkins; 2002. 488 p.
22. Schwendicke F, Tzschoppe M, Paris S. Radiographic caries detection: a systematic review and meta-analysis. *J Dent.* août 2015;43(8):924-33.
23. Geibel M-A, Carstens S, Braisch U, Rahman A, Herz M, Jablonski-Momeni A. Radiographic diagnosis of proximal caries—influence of experience and gender of the dental staff. *Clin Oral Investig.* déc 2017;21(9):2761-70.
24. Srivastava MM, Kumar P, Pradhan L, Varadarajan S. Detection of tooth caries in bitewing radiographs using deep learning. *ArXiv171107312 Cs* [Internet]. nov 2017 [cité 27 sept 2020]; Disponible sur: <http://arxiv.org/abs/pdf/1711.07312.pdf>
25. Choi J, Eun H, Kim C. Boosting proximal dental caries detection via combination of variational methods and convolutional neural network. *J Signal Process Syst.* janv 2018;90(1):87-97.
26. Lee J-H, Kim D-H, Jeong S-N, Choi S-H. Detection and diagnosis of dental caries using a deep learning-based convolutional neural network algorithm. *J Dent.* 2018;77:106-11.
27. Cantu AG, Gehrung S, Krois J, Chaurasia A, Rossi JG, Gaudin R, et al. Detecting caries lesions of different radiographic extension on bitewings using deep learning. *J Dent.* sept 2020;100:103425.
28. Ekert T, Krois J, Meinhold L, Elhennawy K, Emara R, Golla T, et al. Deep learning for the radiographic detection of apical lesions. *J Endod.* juill 2019;45(7):917-922.e5.
29. Tonetti MS, Jepsen S, Jin L, Otomo-Corgel J. Impact of the global burden of periodontal diseases on health, nutrition and wellbeing of mankind: a call for global action. *J Clin Periodontol.* mai 2017;44(5):456-62.
30. John V, Alqallaf H, De Bedout T. Periodontal disease and systemic diseases: an update for the clinician. *J Indiana Dent Assoc.* 2016;95(1):16-23.
31. Petersen PE, Ogawa H. The global burden of periodontal disease: towards integration with chronic disease prevention and control. *Periodontol* 2000. oct 2012;60(1):15-39.

32. Lee J-H, Kim D-H, Jeong S-N, Choi S-H. Diagnosis and prediction of periodontally compromised teeth using a deep learning-based convolutional neural network algorithm. *J Periodontal Implant Sci.* avr 2018;48(2):114-23.
33. Thanathornwong B, Suebnukarn S. Automatic detection of periodontal compromised teeth in digital panoramic radiographs using faster regional convolutional neural networks. *Imaging Sci Dent.* juin 2020;50(2):169-74.
34. Kim J, Lee H-S, Song I-S, Jung K-H. DeNTNet: Deep Neural Transfer Network for the detection of periodontal bone loss using panoramic dental radiographs. *Sci Rep.* nov 2019;9(1):17615.
35. Chang H-J, Lee S-J, Yong T-H, Shin N-Y, Jang B-G, Kim J-E, et al. Deep learning hybrid method to automatically diagnose periodontal bone loss and stage periodontitis. *Sci Rep.* mai 2020;10(1):7531.
36. Tonetti MS, Greenwell H, Kornman KS. Staging and grading of periodontitis: framework and proposal of a new classification and case definition. *J Periodontol.* 2018;89 (Suppl 1):S159-72.
37. Krois J, Ekert T, Meinhold L, Golla T, Kharbot B, Wittemeier A, et al. Deep learning for the radiographic detection of periodontal bone Loss. *Sci Rep.* juin 2019;9(1):8495.
38. Demirjian A, Goldstein H, Tanner JM. A new system of dental age assessment. *Hum Biol.* mai 1973;45(2):211-27.
39. Back W de, Seurig S, Wagner S, Marré B, Roeder I, Scherf N. Forensic age estimation with Bayesian convolutional neural networks based on panoramic dental X-ray imaging. In 2019 [cité 8 nov 2020]. Disponible sur: <https://openreview.net/forum?id=SkesoBY49E>
40. De Tobel J, Radesh P, Vandermeulen D, Thevissen PW. An automated technique to stage lower third molar development on panoramic radiographs for age estimation: a pilot study. *J Forensic Odontostomatol.* déc 2017;35(2):42-54.
41. Matsuda S, Miyamoto T, Yoshimura H, Hasegawa T. Personal identification with orthopantomography using simple convolutional neural networks: a preliminary study. *Sci Rep.* août 2020;10(1):13559.
42. Tuzoff DV, Tuzova LN, Bornstein MM, Krasnov AS, Kharchenko MA, Nikolenko SI, et al. Tooth detection and numbering in panoramic radiographs using convolutional neural networks. *Dentomaxillofacial Radiol.* mars 2019;48(4):20180051.
43. Chen H, Zhang K, Lyu P, Li H, Zhang L, Wu J, et al. A deep learning approach to automatic teeth detection and numbering based on object detection in dental periapical films. *Sci Rep.* mars 2019;9(1):3840.
44. Men K, Chen X, Zhang Y, Zhang T, Dai J, Yi J, et al. Deep deconvolutional neural network for target segmentation of nasopharyngeal cancer in planning computed tomography images. *Front Oncol.* déc 2017;7:315.
45. Esteva A, Kuprel B, Novoa RA, Ko J, Swetter SM, Blau HM, et al. Dermatologist-level classification of skin cancer with deep neural networks. *Nature.* févr 2017;542(7639):115-8.

46. Vinayahalingam S, Xi T, Bergé S, Maal T, de Jong G. Automated detection of third molars and mandibular nerve by deep learning. *Sci Rep.* juin 2019;9(1):9007.
47. Sandler M, Howard A, Zhu M, Zhmoginov A, Chen L-C. MobileNetV2: inverted residuals and linear bottlenecks. *ArXiv180104381 Cs* [Internet]. 21 mars 2019 [cité 24 oct 2020]; Disponible sur: <http://arxiv.org/abs/pdf/1801.04381.pdf>
48. Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. *ArXiv14091556 Cs* [Internet]. 10 avr 2015 [cité 24 oct 2020]; Disponible sur: <http://arxiv.org/abs/pdf/1409.1556.pdf>
49. TensorFlow. TensorFlow White Papers [Internet]. TensorFlow. [cité 12 nov 2020]. Disponible sur: <https://www.tensorflow.org/about/bib>
50. Chollet F. Keras [Internet]. GitHub. 2015. Disponible sur: <https://github.com/fchollet/keras>
51. Uijlings JRR, van de Sande KEA, Gevers T, Smeulders AWM. Selective search for object recognition. *Int J Comput Vis.* sept 2013;104(2):154-71.
52. ImageNet [Internet]. [cité 23 oct 2020]. Disponible sur: <http://www.image-net.org/>
53. Lin T-Y, Maire M, Belongie S, Bourdev L, Girshick R, Hays J, et al. Microsoft COCO: Common Objects in Context. *ArXiv14050312 Cs* [Internet]. 20 févr 2015 [cité 23 oct 2020]; Disponible sur: <http://arxiv.org/abs/pdf/1405.0312.pdf>

## 7. Table des illustrations

<i>Figure 1. Schéma décrivant le fonctionnement de l'apprentissage supervisé en deep learning.</i>	10
<i>Figure 2. Nombre de publications annuelles dans la base de données PubMed en septembre 2020.</i>	11
<i>Figure 3. Illustration d'un filtre ou matrice de convolution.</i>	14
<i>Figure 4. Schéma décrivant le processus d'apprentissage du réseau de neurones.</i>	15
<i>Figure 5. Explication des couches de convolution et de pooling lors de l'application de réseaux de neurones convolutifs à une image.</i>	16
<i>Figure 6. Différence entre une classification et une identification.</i>	17
<i>Figure 7. Résultats de détection du niveau osseux parodontal (a–e), de la jonction émail-cément (f–j), et des dents ou implants (k–o) par le réseau de neurones développé.</i>	23
<i>Figure 8. Exemples d'images correctement annotées par le réseau de neurones sur des radiographies tests.</i>	25
<i>Figure 9. Comparaison des segmentations automatiques et manuelles des troisièmes molaires mandibulaires et du nerf alvéolaire inférieur.</i>	26
<i>Figure 10. Exemple de l'utilisation de l'augmentation du jeu de données à partir d'une image.</i>	29
<i>Figure 11. Pipeline montrant les données utilisées pour l'apprentissage des deux modèles.</i>	31
<i>Figure 12. Graphique représentant l'évolution de la précision et de l'erreur du modèle au cours des cycles d'apprentissage.</i>	32
<i>Figure 13. Pipeline développant l'ensemble des étapes d'annotation de la méthode développée et appliquée à une radiographie rétro-alvéolaire.</i>	35
<i>Figure 14. Exemples d'annotations correctes réalisées par le modèle.</i>	36
<i>Figure 15. Exemples d'éléments non annotés par le modèle développé.</i>	36
<i>Figure 16. Exemples d'annotations incorrectes par le modèle.</i>	37

## 8. Liste des tableaux

<i>Tableau 1. Résumé des applications cliniques, des données et des performances des systèmes d'analyse automatique d'images en dentisterie dans la littérature.</i>	26
<i>Tableau 2. Jeu de données obtenu suite à la phase d'annotation des images radiographiques.</i>	29
<i>Tableau 3. Nombre d'images utilisées pour chacune des trois classes « dent non restaurée », « dent restaurée par soin OC » et « dent couronnée et dépulpée ».</i>	30
<i>Tableau 4. Performance du modèle classifiant « dent » et « non-dent ».</i>	33
<i>Tableau 5. Performance du modèle classifiant « dent non restaurée », « dent restaurée par soin OC » et « dent couronnée et dépulpée ».</i>	33

**UNIVERSITÉ DE NANTES**  
**UNITÉ DE FORMATION ET DE RECHERCHE D'ODONTOLOGIE**

---

**Vu le Président du Jury,**

*Vu et permis d'imprimer*

**Vu le Doyen,**

**Pr Bernard GIUMELLI**

**WEYDER (Mathias).** – Détection et classification automatique des dents sur les radiographies dentaires. – 48 f. ; ill. ; tabl. ; 53 ref. ; 30 cm (Thèse : Chir. Dent. ; Nantes ; 2021)

#### RESUME

L'objectif de ce travail est de fournir une meilleure compréhension de l'apport de l'intelligence artificielle dans la problématique de l'analyse automatique d'images radiographiques en odontologie. Ainsi, une analyse de la littérature scientifique portant sur les approches utilisant le *deep learning* dans l'analyse d'examen radiographiques montre l'essor récent et exponentiel de l'application des réseaux neuronaux convolutifs dans plusieurs champs disciplinaires comme en odontologie conservatrice, en parodontologie et en odontologie médico-légale.

De plus, au travers d'un projet mené lors de cette thèse sous la forme d'un programme informatique détectant les organes dentaires sur des clichés radiographiques, une utilisation pratique de l'intelligence artificielle en odontologie est présentée.

RUBRIQUE DE CLASSEMENT : Radiologie

#### MOTS CLES MESH

Radiographie dentaire - Radiography, dental

Apprentissage profond - Deep learning

Diagnostic assisté par ordinateur - Diagnosis, computer-assisted

Réseaux neuronaux (ordinateur) - Neural networks (computer)

Apprentissage machine supervisé - Supervised Machine Learning

#### JURY

Président : Professeur AMOURIQ Y.

Assesseur : Professeur LE GUEHENNEC L.

Assesseur : Professeur GUEDON J-P.

Directeur : Docteur JORDANA F.

Co-directeur : Professeur AMOURIQ Y.

#### ADRESSE DE L'AUTEUR

11 rue Bias - 44000 Nantes

[mathiasweyder@gmail.com](mailto:mathiasweyder@gmail.com)