

الجمهورية الجزائرية الديمقراطية الشعبية
République Algérienne démocratique et populaire

وزارة التعليم العالي والبحث العلمي
Ministère de l'enseignement supérieur et de la recherche scientifique

جامعة سعد دحلب البلدية
Université SAAD DAHLAB de BLIDA

كلية التكنولوجيا
Faculté de Technologie

قسم الإلكترونيك
Département d'Électronique



Mémoire de Master

Mention : Génie Biomédicale

Spécialité : Instrumentation Biomédicale

Présenté par :

Issad Nihad

&

Si-Hadi Sarah

Détection de Caries Dentaires par Deep Learning

Proposé par : Dr. A. Chentir

Année Universitaire : 2021/2022

Dédicace

Avec l'expression de ma reconnaissance, je dédie ce modeste travail à ceux qui, quels que soient les termes embrassés, je n'arriverais jamais à leur exprimer mon sincère amour :

*A la femme qui a souffert sans me laisser souffrir, qui n'a jamais dit non à mes exigences et qui n'a épargné aucun effort pour me rendre heureuse, **mon adorable mère Zakia**.*

*A l'homme qui était toujours à mes côtés pour me soutenir et m'encourager, que ce travail traduit ma gratitude et mon affection, **mon cher papa Ali**.*

*A ma petite fille adorable **Eline**, ma précieuse offre de Dieu, qui m'a entouré d'amour et qui sait toujours procurer la joie et le bonheur à toute la famille. A mes chers frères **Mohamed Amine** et **Abd Erahmene** et à ma petite sœur **Niema**, puisse Dieu leur donner santé, bonheur, courage et surtout réussite.*

*A ma meilleure amie **Fella**, qui a partagé avec moi tous les moments d'émotions lors de la réalisation de ce travail, je lui souhaite une joyeuse vie et plus de succès.*

*Sans oublier **mon binôme Sarah** qui m'a supporté toute au long de ce parcours, je lui souhaite tout le bonheur et la réussite.*

Nihad.

Dédicace

C'est avec toute mon affection que je dédie ce modeste travail à tous ceux qui me sont chers.

A mes chers parents Si-Hadi Mohamed et Nait Cherif Nadia, pour tous leurs sacrifices, leur amour, leur tendresse, leur soutien et leurs prières tout au long de mes études.

A ma chère sœur Nawel et son mari Hamza, pour ses soutiens moraux et leurs précieux conseils.

A mes chers frères, Samir et sa femme Amira, Adel, Billel, pour leur appui et leur encouragement.

A ma chère cousine Katia, que Dieu lui donne une longue et joyeuse vie.

Et à toute ma famille et mes ami(e)s sans exception, pour leurs aides et supports dans les moments difficiles.

Sans oublier mon binôme Nihed pour son soutien moral, sa patience et sa compréhension tout au long de ce travail et à toute sa famille.

Sarah.

Remerciements

Au terme de la rédaction de ce mémoire, c'est un devoir agréable d'exprimer en quelques lignes la reconnaissance que nous devons à tous ceux qui ont contribué de près ou de loin à l'élaboration de ce travail, qu'ils trouvent ici nos vifs respects et notre profonde gratitude.

On remercie tout d'abord notre Dieu qui nous a donné la force pour terminer ce modeste travail.

Nos vifs remerciements vont à Dr. A. Chentir pour son encadrement, sa disponibilité et son aide précieuse.

Nous tenons à remercier aussi les membres du jury pour l'honneur qu'ils nous font en acceptant de juger et évaluer notre travail.

Et enfin un grand merci à nos familles qui nous ont toujours soutenu et encouragé et à tous ceux qui ont contribué de près ou de loin à l'élaboration de ce modeste travail.

الملخص:

تم تطوير العديد من الطرق والخوارزميات للتعرف على تسوس الأسنان وتصنيفه في المرضى المصابين. من بين كل هذه من خلال تطبيق نقل التعلم على قاعدة بيانات. لهذا الغرض، استخدمنا العديد CNN التقنيات، اخترنا لمشروع التخرج نهج VGG16 بعد اختبارها وجدنا أن (VGG16 و VGG19 و Inception-ResNet V2) من الطرز المدربة مسبقاً يؤدي بشكل أفضل في تصنيف تسوس الأسنان بدقة 97.06% في الاختبار. التطبيق الذي تم تنفيذه يجعل من الممكن تصنيف تسوس الأسنان وإعطاء النسبة المئوية لنوع الأخير.

الكلمات الجوهرية: تصنيف، سي إن إن، التجايف، طب الأسنان، نقل التعلم.

Résumé :

Plusieurs méthodes et algorithmes ont été développés pour la reconnaissance et la classification de la carie dentaire chez les patients malades. Parmi toutes ces techniques, nous avons choisi pour notre projet de fin d'études, l'approche CNN en appliquant l'apprentissage par transfert sur une base de données. Pour cela, nous avons utilisé plusieurs modèles pré-entraînés (VGG16, VGG19 et Inception-ResNet V2). Après avoir testé ces derniers, nous avons constaté que le VGG16 est le plus performant en classification de la carie dentaire avec une précision de 97,06 % en test. L'application réalisée permet de classifier la carie dentaire et donner le pourcentage du type de cette dernière.

Mots clés : Classification, CNN, Caries Dentaires, VGG16, VGG19, Inception-ResNet V2, Apprentissage par Transfert.

Abstract:

Several methods and algorithms have been developed for the recognition and classification of dental caries in diseased patients. Among all these techniques, we chose for our graduation project, the CNN approach by applying transfer learning on a database. For this, we used several pre-trained models (VGG16, VGG19 and Inception-ResNet V2). After testing these, we found that the VGG16 performs best in classifying tooth decay with an accuracy of 97.06% in testing. The application carried out makes it possible to classify dental caries and give the percentage of the type of the latter.

Keywords : Classification, CNN, Dental Caries, VGG16, VGG19, Inception-ResNet V2, Transfer Learning.

Table des Matières

Dédicaces	
Remerciements	
Résumés	
Table des Matières	i
Liste des Figures	iv
Liste des Tableaux	v
Liste des Abréviations	vii
Introduction Générale	1
I Chapitre I	3
I.1 Introduction	3
I.2 Anatomie de la cavité dentaire buccale	3
I.2.1 Anatomie de la dent	4
I.2.2 La morphologie des dents	5
I.2.3 La fonction des dents	7
I.3 Maladies dentaires	7
I.3.1 La maladie parodontale	8
I.3.2 La carie dentaire	10
I.4 Imagerie dentaire pour la détection des caries.....	13
I.4.1 Radiographie rétro-coronaire (Bite-Wing).....	14
I.4.2 Radiographie périapicale.....	15
I.4.3 Radiographie occlusale	15
I.4.4 Radiographie panoramique	15
I.4.5 Radiographie céphalométrique	16
I.4.6 Radiographie à faisceau conique (Cone Beam).....	16
I.5 Conclusion.....	17
I.1 Introduction	17

I.2	Méthodes de Détection et de Classification	17
I.3	Tableau récapitulatif	24
I.4	Conclusion.....	33
II	Chapitre III.....	34
III	34	
III.1	Introduction.....	34
III.2	L'apprentissage supervisé /non supervisé	34
III.2.1	L'apprentissage supervisé.....	34
III.2.2	Apprentissage automatique non supervisé	35
III.3	L'intelligence artificielle en radiologie dentaire.....	35
III.4	Étude comparative des différents algorithmes de l'intelligence artificielle	36
III.4.1	Support Vector Machines (SVM)	36
III.4.2	Arbre de décision	37
III.4.3	La régression logistique.....	38
III.4.4	Le Deep Learning.....	39
III.4.5	Réseau de Neurones	40
III.4.6	Les Réseaux de Neurones Convolutifs.....	41
III.5	Apprentissage par transfert (Transfer Learning).....	45
III.6	Paramètres d'évaluation du modèle CNN	49
III.7	Conclusion	51
IV	Chapitre IV.....	1
	Résultats d'Implémentation.....	1
IV.1	Introduction.....	51
IV.2	Base de Données utilisée	51
IV.3	Environnement et bibliothèques	52
IV.3.1	Google Colaboratory	52
IV.3.2	Python.....	53

IV.3.3	Tensor Flow	53
IV.3.4	Keras	54
IV.3.5	Gradio	54
IV.4	Développement de l'Application	55
IV.4.1	Méthodologie de programmation suivie	57
IV.4.2	Résultats et interprétation	64
IV.5	Développement d'une interface graphique	70
IV.6	Conclusion	71
	Bibliographie	71
	Annexes	

Liste des Figures

Figure I-1 : Cavité buccale	3
Figure I-2 : Représentation schématique de la dent	4
Figure I-3 : La morphologie de la dent..	6
Figure I-4 : Exemple de la maladie de la gencive ou la parodontale.	9
Figure I-5 : Exemple d'une carie dentaire	10
Figure I-6 : Taux d'acidité (pH) dans la bouche.	11
Figure I-7 : Abscès à la base de la racine	13
Figure I-8 : Types de radiographies dentaires	14
Figure I-9 : Radio Bite-wing	14
Figure III-1 : Exemple d'apprentissage automatique supervisé	35
Figure III-2 : Exemple d'apprentissage Automatique non supervisé	35
Figure III-3 : Qualité des soins dentaires avec la puissance de l'IA	36
Figure III-4 : Explications de l'SVMs	37
Figure III-5 : Structure de l'arbre de décision	38
Figure III-6 : Exemple d'une régression logistique.	39
Figure III-7 : La relation entre les 3 domaines	40
Figure III-8 : Schéma représentant l'architecture d'un CNN.....	42
Figure III-9 : Illustration des différentes couches de CNN.....	45
Figure III-10 : Architecture du VGG16.....	46
Figure III-11 : Présentation de l'architecture VGG-16 en 3D	47
Figure III-12 : Illustration de l'Architecture VGG19	48
Figure III-13 : Schéma de principe d'Inception-ResNet-v2.....	48
Figure III-14 : Matrice de Confusion.....	50
Figure IV-1 : Exemple d'images de dents saines.	51
Figure IV-2 : Exemple d'images de caries dentaires.	52
Figure IV-3 : Logo de Colaboratory	53
Figure IV-4 : Logo de python	53
Figure IV-5 : Logo de Tensor Flow	54
Figure IV-6 : Logo de Keras	54
Figure IV-7 : Organigramme Général.....	56
Figure IV-8 : Une image de notre base de données.	59
Figure IV-9 : Configuration du "Modèle 1".	62
Figure IV-10 : Configuration du "Modèle 2".	63

Figure IV-11 : Résultat de la phase d'apprentissage "Modèle 1".....	65
Figure IV-12 : L'évaluation du "Modèle 1".....	65
Figure IV-13 : Exemple d'un résultat de prédiction "Modèle 1".....	66
Figure IV-14 : Matrice de confusion "Modèle1".....	66
Figure IV-15 : Résultat de la phase d'apprentissage "Modèle 2".....	68
Figure IV-16 : L'évaluation du "Modèle 2".....	68
Figure IV-17 : Exemple d'un résultat de prédiction "Modèle 2".....	69
Figure IV-18 : Matrice de confusion "Modèle 2".....	69
Figure IV-19 : Interface Graphique développée.....	70

Liste des Tableaux



Liste des Tableaux

Tableau IV-1 : Informations sur la Base de Données.	51
Tableau IV-2 : Les Paramètres utilisés pour la Phase d'Apprentissage "Modèle 1" ...	61
Tableau IV-3 : L'optimisateur Adam.	61
Tableau IV-4 : Paramètres utilisés pour la phase d'apprentissage (Modèle 2).....	62
Tableau IV-5 : L'optimisateur Adam.	63
Tableau IV-6 : Tableau comparatif des deux Modèles réalisés.	70

Liste des Abréviations

API	: Application Programming Interface.
CNN	: Convolutional Neural Network.
CBCT	: Cone Beam Computed Tomography.
FCL	: Fully Connected Layer.
Fn	: False negative.
Fp	: False positive.
GPU	: Graphics Processing Unit.
IA	: Intelligence Artificielle.
ML	: Machine Learning.
OMS	: Organisation Mondiale de la Santé.
pH	: potentiel Hydrogène.
RVB	: Rouge, Vert ; Bleu.
ReLU	: Rectified Linear Unit.
ROC	: Receiver Operating Characteristic.
SIDA	: Syndrome d'Immuno-Déficiência Acquis.
SVM	: Support Vector Machine.
TPU	: Tensor Processing Unit.
Tp	: True positive.
Tn	: True negative.
VIH	: Human Immunodeficiency Viruses.

Introduction

Générale

La carie dentaire est une maladie infectieuse qui se développe lentement et détruit progressivement les tissus durs de la dent. La carie dentaire est la maladie la plus courante dans le monde. Elle affecte la grande majorité de la population, les enfants comme les adultes.

Les données épidémiologiques émanant de l'OMS (Organisation Mondiale de la Santé) soutiennent que la carie dentaire reste aujourd'hui encore, un des plus grands fléaux mondiaux après le virus du SIDA, le paludisme et les maladies cardio-vasculaires.

Les preuves scientifiques montrent que les premiers stades de la carie peuvent être arrêtés et éventuellement inversés par une intervention non invasive, telle que la réduction du régime cariogène et l'amélioration de l'hygiène bucco-dentaire. Cette opportunité d'inverser le développement de la carie de manière non-invasive, introduit un défi quotidien pour les dentistes afin de déterminer si une intervention non-invasive ou réparatrice est nécessaire en fonction de la gravité de l'activité de la lésion carieuse.

L'altération grave de la santé et de la qualité de vie des individus atteints et l'importance du fardeau sociétal requièrent une approche inter professionnelle dans la dispensation des soins aux caries dentaires afin d'en optimiser la prise en charge, Il est ainsi pertinent de s'intéresser à développer un outil d'aide au diagnostic par l'intelligence artificielle qui va amplifier le potentiel humain.

L'IA pourrait s'avérer très utile dans le cadre de classifier l'ulcère de la carie dentaire et donc de faciliter le diagnostic qui est un point essentiel pour une meilleure prise en charge.

Un certain nombre de technologies existent pour le diagnostic des caries comprennent les dispositifs basés sur le laser ou l'infra-rouge, la mesure de conductance électrique ou la radiographie numérique directe. Cette dernière est la technologie la plus utilisée car elle facilite le diagnostic et l'identification de plusieurs maladies bucco-dentaires, ce qui a attiré l'attention de la communauté scientifique à réaliser des systèmes informatiques automatiques pour la détection et la classification des caries dentaires, afin de faciliter le processus de diagnostic pour le dentiste.

L'objectif de notre projet fin d'étude est de trouver un algorithme robuste afin de réaliser une application qui va nous permettre d'obtenir une classification fiable de la carie dentaire et de donner le pourcentage de cette dernière pour aider le dentiste à évaluer le pronostic et de permettre une prise en charge adaptée à chaque type de carie dans le but d'éviter l'extraction de la dent.

La structure de ce mémoire est fondée sur 4 chapitres :

- Après cette introduction générale, le premier chapitre sera consacré à la description anatomique de la dent et à la description physiopathologique de la carie dentaire, en particulier la complication la plus grave de cette dernière, dans laquelle le problème a été évoqué.

- Concernant le deuxième chapitre, qui s'intitule État de l'Art, nous parlerons des différentes méthodes, architectures et techniques qui ont été proposées ces dernières années pour la détection et la classification de la carie dentaire.

- Le troisième chapitre sera consacré aux approches et aux méthodes que nous avons utilisées pour la classification en imagerie médicale. Ainsi, des tests et des organigrammes bien détaillés seront présentés pour chaque méthode étudiée.

- Le dernier chapitre intitulé Résultats d'implémentation, sera consacré à la présentation et à l'interprétation des résultats qui seront regroupés dans une interface graphique finale.

- Une conclusion générale viendra clôturer notre travail.

Chapitre I

Aspect Médical

I.1 Introduction

Nous savons que les dents sont utiles pour manger, qu'elles influencent sur notre apparence esthétique et que nous devons en prendre soin. Les dents sont remplacées (dentition primaire) durant l'enfance et certaines peuvent être fragilisées vers un âge avancé. Nous savons également que notre dentition peut être source d'inconforts, de douleurs et d'inquiétudes et qu'une meilleure connaissance de cette composante du corps humain est plus que souhaitable [1].

Dans ce chapitre, nous commencerons par une petite description anatomique de la dent, les maladies dentaires et leurs complications, puis nous terminerons avec l'imagerie dentaire en odontostomatologie (médecine de la bouche et de la dentition).

I.2 Anatomie de la cavité dentaire buccale

La cavité buccale (Figure I-1), aussi appelée la bouche, comprend normalement 32 dents. Elle est délimitée sur le dessus par le palais (ou voûte palatine), sur le dessous par la langue, sur les côtés par les joues, sur le devant par les lèvres et à l'arrière par le pharynx.

La cavité buccale constitue le point de départ du système digestif. Le travail de mastication effectué par les dents est très important pour la suite de la digestion. La cavité buccale peut être atteinte de nombreuses pathologies. Parmi les plus courantes citons les caries dentaires et la gingivite (inflammation de la gencive) [10].

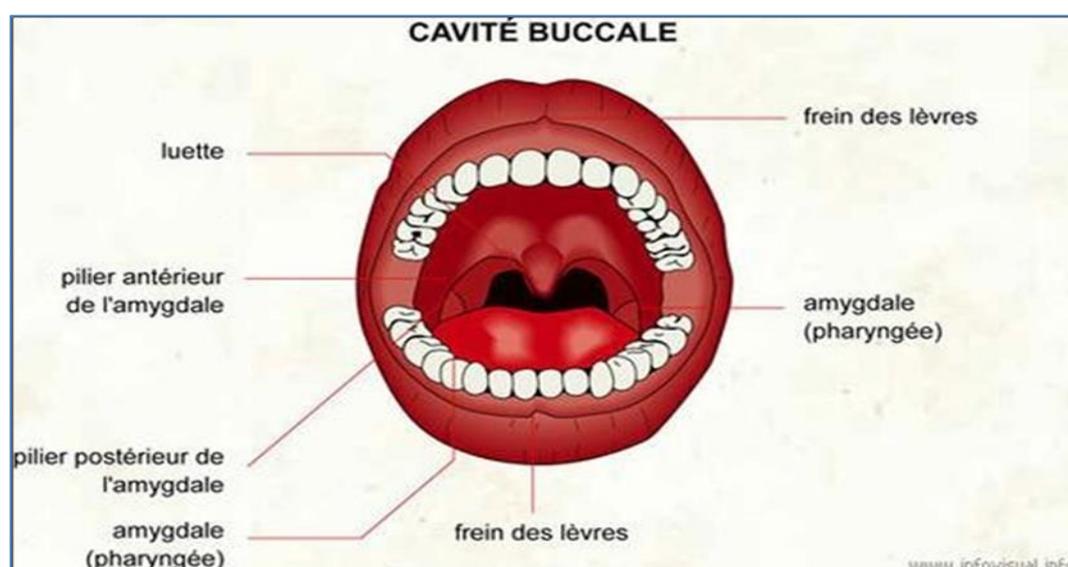


Figure I-1 : Cavité buccale [2].

I.2.1 Anatomie de la dent

La dent est l'organe le plus dur du corps humain. C'est un organe enveloppé d'os, dur, blanchâtre, généralement composé d'une couronne libre et d'une ou plusieurs racines implantées dans la cavité buccale. Plus particulièrement dans l'os alvéolaire des os maxillaires (maxillaire et mandibule) et est destiné notamment à couper et à broyer les aliments [3].

La Figure I-2 présente un aperçu détaillé des différents tissus qui constituent la dent.

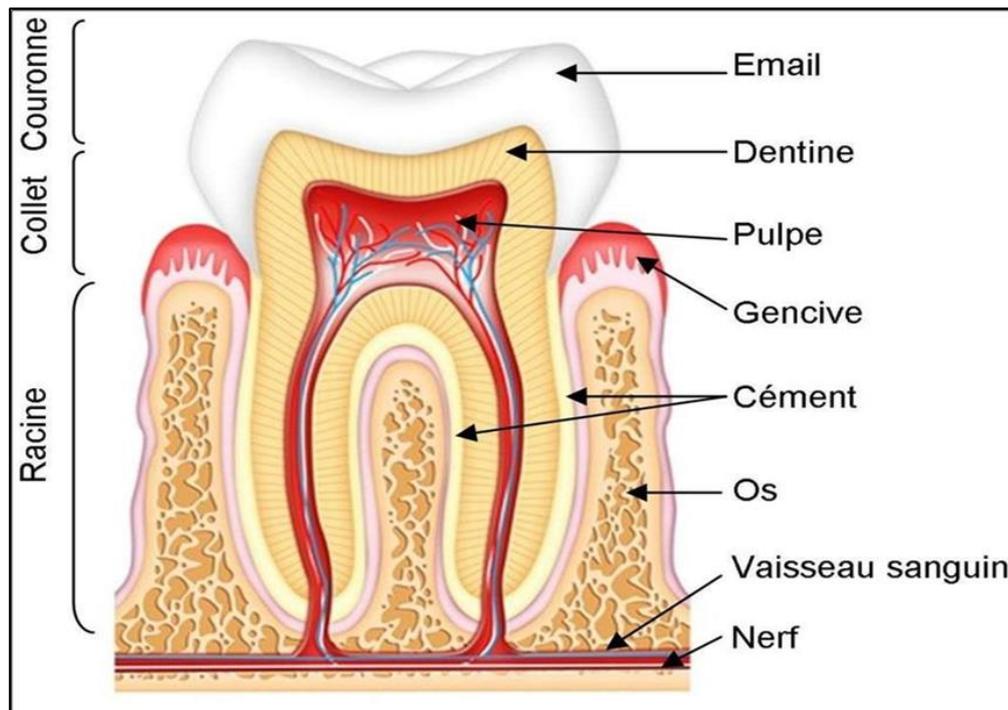


Figure I-2 : Représentation schématique de la dent [3].

Chaque dent comporte une partie visible extra-osseuse, la couronne, une partie intra osseuse, la racine, séparée l'une de l'autre par le collet.

- ✓ La couronne est la partie supérieure et visible de la dent. Elle est formée de 3 couches :
 - **Email** : Tissu le plus dur de l'organisme qui contient 95 % de substances minérales. Plus ou moins translucide, il laisse apparaître la couleur de la dentine sous-jacente.
 - **Dentine** : tissu de soutien de l'émail qui constitue l'essentiel de la dent. C'est un tissu minéral plus poreux que l'émail.

- **Pulpe** : tissu conjonctif à l'intérieur de la dent qui lui donne sa vitalité et sa sensibilité. Elle renferme les nerfs, les vaisseaux lymphatiques, les veines et les artères. Ceux-ci sont en continuité avec les vaisseaux sanguins de la face du visage.
 - ✓ Le collet de la dent est la partie présente à la limite entre la couronne et la racine. C'est donc la partie située juste à la jonction avec la gencive.
 - ✓ La racine est la partie de la dent située à l'intérieur de l'os du maxillaire. Elle constitue deux tiers environ de la dent et a le rôle de fixer la dent dans l'os. C'est la portion de la dent qui est incluse dans l'alvéole dentaire [5].

I.2.2 La morphologie des dents

La Figure I-3 présente les différentes catégories de dents rencontrées chez l'être humain.

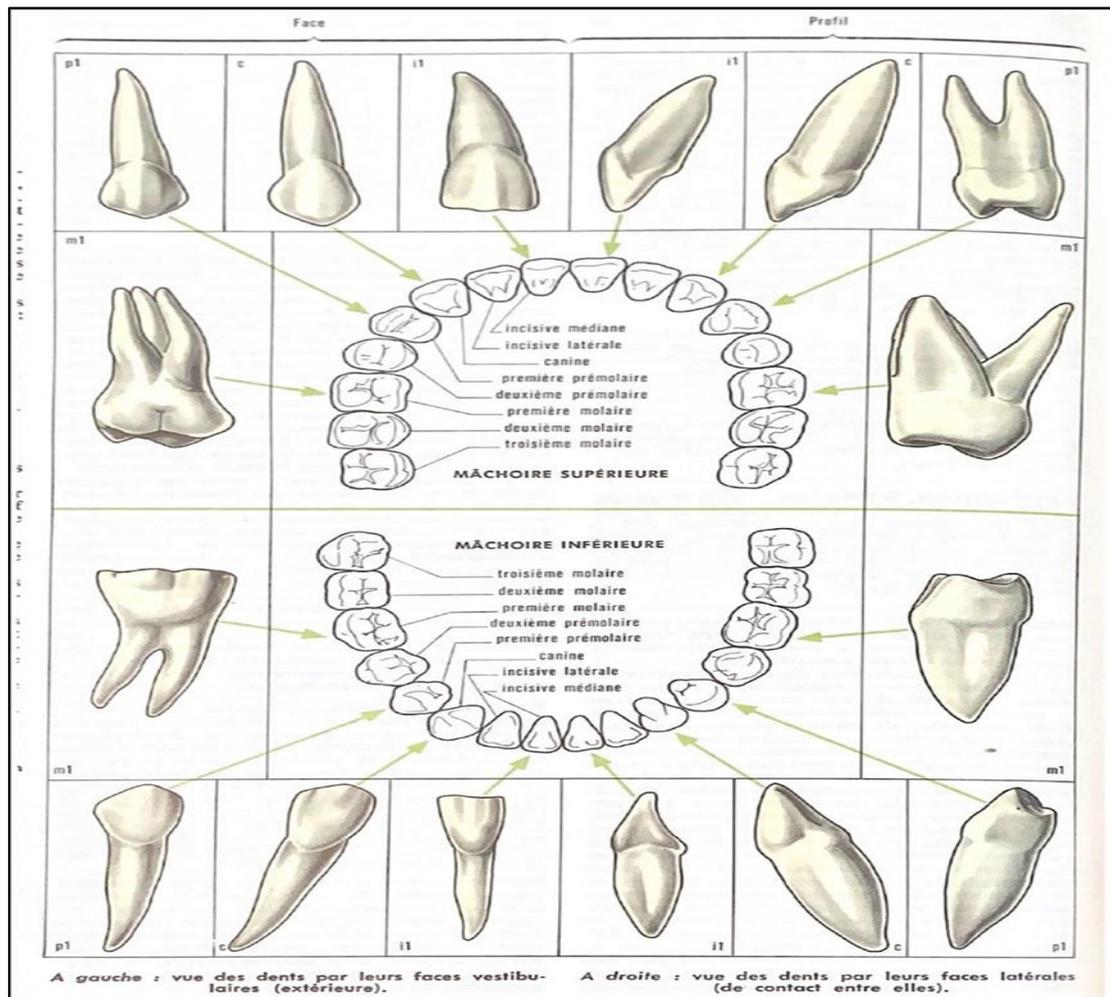


Figure I-3 : La morphologie de la dent. (Source la rousse la page 310).

Ainsi, nous avons :

- **Les incisives** : Les dents plates et aux extrémités acérées à l'avant de la bouche. Au nombre de 8 (4 en haut et 4 en bas), leur fonction est de couper et de mordre la nourriture.
- **Les canines** : Dents longues et pointues profondément enracinées. Elles se trouvent à côté des incisives. Leur fonction est de déchiqueter la nourriture (2 en haut et 2 en bas).
- **Les prémolaires** : se trouvent derrière les canines. Elles possèdent 2 pointes proéminentes connues sous le nom de « cuspides » et 1 ou 2 racines. Ces 8 prémolaires (4 en haut et 4 en bas) ont pour fonction de déchiqueter et de broyer la nourriture.

- **Les molaires** : Dents du fond, chacune avec 4 ou 5 cuspides. Les 6 molaires supérieures possèdent généralement 3 racines alors que les 6 molaires inférieures possèdent généralement 2 racines. Leur Fonction est de mâcher et de broyer la nourriture [4].

I.2.3 La fonction des dents

Les dents ont plusieurs rôles importants en :

- **Alimentation** : les incisives permettent de sectionner les aliments (ou autre chose) ; les molaires et prémolaires permettent la mastication, le broyage des aliments et les canines permettent de déchiqueter les aliments comme la viande.
- **Phonétique** : les dents, en association avec la langue et les lèvres, permettent de prononcer de nombreux phonèmes.
- **Esthétique** : elles soutiennent les tissus mous qui les entourent (lèvres, joues) et participent au sourire.
- **Attaque et défense, pour de nombreux êtres vivants (humains et animaux)** : il s'agit d'armes. Par exemple, les dents des serpents venimeux qui sont percées de canaux à venin ou celles des cétacés mysticètes, comme les baleines grises, qui sont allongées en fanons et servent de filtres [3].

I.3 Maladies dentaires

Il existe deux formes principales de maladies dentaires : la maladie parodontale (maladie des gencives) et la carie dentaire (destruction de la dent) [4].

La cause principale de ces deux formes de maladies correspond à une substance appelée « Plaque dentaire » qui est une pellicule relativement fine et collante formée à partir d'un mélange de salive et de bactéries.

Présente chez la plupart des individus, elle adhère à la surface des dents et sur l'extrémité de celles-ci bordant les gencives, ainsi qu'entre les dents. Si l'on ne se débarrasse pas régulièrement de cette plaque, les bactéries commencent à attaquer le bord des gencives entraînant une inflammation ce qui constitue la première étape d'une maladie parodontale.

Si la plaque dentaire se développe, elle va se combiner aux agents chimiques de la salive et commencer à se calcifier, pour former une matière blanchâtre solide qui s'accumule autour des dents. C'est ce que l'on désigne sous le nom de calcul ou tartre. À ce stade, on ne peut plus enlever le tartre avec un simple brossage.

Les bactéries présentes dans la plaque dentaire peuvent également favoriser la synthèse des glucides en acides qui attaquent et déminéralisent la surface des dents pour entamer le processus de destruction [4].

I.3.1 La maladie parodontale

Il est très fréquent qu'un nombre de dents encore saines doivent être arrachées à cause d'une maladie parodontale (Figure I-4), provoquée par le développement d'une plaque dentaire. Les trois stades par lesquelles passe cette maladie des gencives sont comme suit :

- **Léger** : Lorsqu'on laisse trop de plaque dentaire demeurer autour des collets des dents, les gencives s'enflamment (c'est ce que l'on connaît sous le nom de gingivite).
- **Modéré** : Si la gingivite persiste, les gencives gonflent autour des dents, permettant à la plaque dentaire et aux bactéries de pénétrer dans les fibres parodontales et de détruire l'os de soutien. Ce phénomène est connu sous le nom de parodontite.
- **Avancé** : Si la parodontite reste sans surveillance, l'os de soutien se trouve tellement affaibli que la dent en devient mobile et finit par tomber [4].



Figure I-4 : Exemple de la maladie de la gencive ou la parodontale [5].

❖ **Grossesse et maladie parodontale :**

La grossesse entraîne des changements hormonaux de sorte que saignements et gencives gonflées sont plus courants chez la femme enceinte. Il faut faire preuve de soins et d'une vigilance extrême, en matière d'hygiène bucco-dentaire et de régime alimentaire, afin d'assurer une bonne santé à la mère et à l'enfant.

❖ **Facteurs de risque associés à une maladie parodontale :**

- ✓ Tabagisme et stress émotionnel peuvent être à l'origine ou aggraver la dégradation du tissu gingival.
- ✓ VIH et SIDA : affectent le corps, son système immunitaire et sa résistance aux maladies.
- ✓ Le diabète sucré insulino-dépendant en particulier peut influencer sur l'hygiène bucco-dentaire, surtout si la maladie n'est pas bien contrôlée.

❖ **Des dents saines ne sont rien sans des gencives saines :**

Les gencives tiennent toute la dentition en place et éloignent les débris alimentaires des dents à l'intérieur de la bouche. Ils font en outre office de barrière protectrice pour les dents face aux germes et infections, ainsi dents saines et gencives saines vont de pair.

I.3.2 La carie dentaire

La destruction de la dent ou bien carie dentaire se développe à la suite de la synthèse de glucides dans la bouche en acides par la plaque dentaire bactérienne. Les acides attaquent alors les dents.

La carie peut démarrer n'importe où sur la dent, bien qu'elle survienne le plus souvent dans les creux et les fissures de la partie coupante des dents (Figure I-5), et entre ces dernières, où la nourriture a tendance à s'accumuler, favorisant la prolifération des bactéries [4].



Figure I-5 : Exemple d'une carie dentaire [5].

La carie dentaire passe par 4 grands stades qui peuvent être résumés comme suit :

- **Stade 1** : Le sucre est synthétisé en acide par la plaque dentaire bactérienne.
- **Stade 2** : L'acide attaque l'émail et la destruction de la dent se met en marche dans la bouche. Les premiers stades de la carie, apparaissant entre les dents, ne sont en général détectables que sur une radiographie.
- **Stade 3** : Lorsque la carie atteint la pulpe dentaire, le nerf est touché et le contact avec des températures extrêmes va être douloureux.
- **Stade 4** : La carie peut s'étendre à toute la pulpe dentaire, provoquant la formation d'abcès. Cela s'avère très douloureux et il faut parfois donc arracher la dent.

❖ Comment prévenir contre la carie ?

Il existe trois méthodes principales pour minimiser la destruction de la dent, voire l'éviter complètement. En théorie, étant donné que la carie ne survient que lorsque des bactéries synthétisent le sucre en acide, on pourrait prévenir son apparition :

1. En évitant de manger du sucre :

Les personnes qui mangent peu ou pas de sucre souffrent rarement de caries et la hausse du taux de caries dentaires dans plusieurs pays moins développés constitue un problème relativement récent.

Dans d'autres pays, on agrmente de sucre de nombreux aliments (par ex. dans les gâteaux, les pâtisseries, les biscuits et les boissons non alcoolisées), augmentant ainsi le nombre de caries. Il suffit de très peu de sucre aux bactéries pour le synthétiser en acide. Cela dure seulement une ou deux minutes et l'acide peut demeurer dans la bouche, à un niveau critique, pendant environ une demie heure (Figure I-6). La synthèse du sucre naturel en acide est plus lente que pour le sucre « industriel » raffiné, qui est altéré chimiquement au cours du processus de fabrication [4].

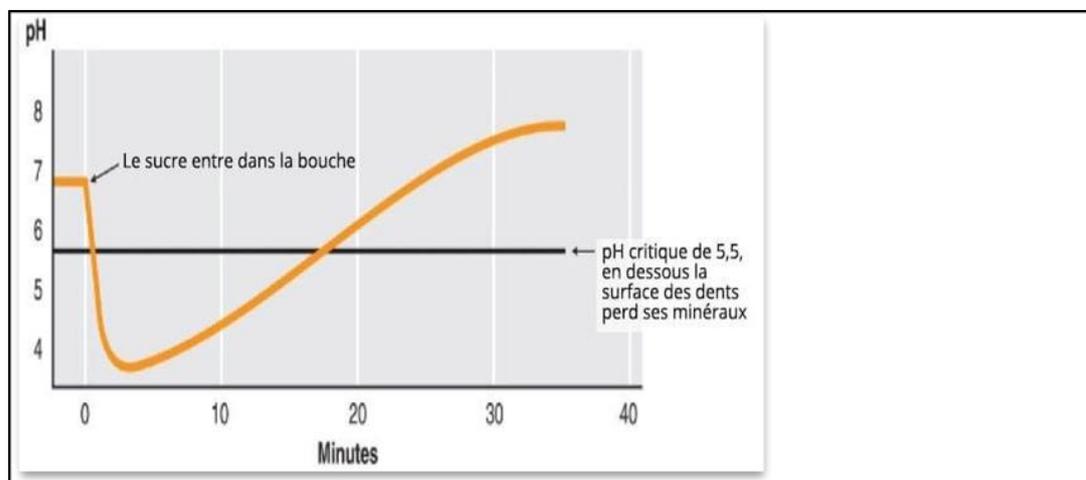


Figure I-6 : Taux d'acidité (pH) dans la bouche [6].

La quantité de sucre consommée est relative à la manière dont elle est consommée. Les aliments collants tels que gâteaux et biscuits colleront aux dents plus longtemps et les boissons sucrées couvrent complètement les dents, les exposant à plus d'acidité.

Si nous nous apprêtons à manger ou boire quelque chose de sucré, il est préférable de l'intégrer à un repas ou de le prendre immédiatement après tout en restreignant notre consommation de sucre à une fois par jour. Par exemple, si un enfant reçoit des bonbons, il

vaut mieux en manger plusieurs d'un seul coup plutôt que de les distribuer tout au long de la journée [4].

2. En augmentant la résistance des dents aux attaques acides :

Le fluor représente un minéral naturellement présent dans la roche, le sol et l'eau. Il s'agit d'un composant de base de l'émail. D'après le département de santé bucco-dentaire de l'OMS, une exposition à la dose de fluor appropriée correspond à la mesure la plus efficace que l'on puisse prendre pour prévenir la carie dentaire, et l'utilisation d'un dentifrice à base de fluor en est un très bon moyen [4].

3. En éliminant les bactéries :

Un brossage soigneux de dents va éliminer la majorité de la plaque dentaire des parties accessibles des dents et des gencives, et cela va aider à prévenir la formation de caries. Pourtant, très peu de gens sont capables de se brosser les dents de manière suffisamment efficace pour éliminer toute trace de plaque dentaire. Par conséquent, réduire la quantité et la fréquence de la consommation de sucre, reste une priorité en termes de prévention [4].

❖ Comment reconnaître une carie dentaire ?

Lorsque l'acide des bactéries commence à déminéraliser la surface de l'émail d'une dent, les premiers signes visibles de carie peuvent tarder avant d'apparaître. Un petit trou va finir par se développer et il continuera à grossir, à moins qu'on n'interrompe sa progression. À ce stade, un dentiste est en mesure d'éliminer la partie de la dent et de procéder à l'obturation du trou. Si on laisse le trou sans surveillance médicale, il va s'élargir et se faire plus profond dans la dent, jusqu'à envahir la chambre pulpaire, affectant le nerf [4].

❖ Les signes classiques de la carie dentaire :

Le début d'une carie est en général indolore, alors que l'acide attaque la surface de l'émail.

On ressent la douleur lorsque la carie attaque la dentine. Cette dernière augmente tandis que la carie atteint la pulpe dentaire. Dans un premier temps, on va ressentir la douleur uniquement lorsque la dent entre en contact avec des aliments chauds, froids, sucrés et acides, mais ensuite devient permanente jusqu'à devenir vive. Si la carie n'est pas soignée, elle va finir par tuer la pulpe dentaire [4].

❖ L'abcès dentaire :

L'abcès dentaire (Figure I-7) est une accumulation de pus liée à une infection bactérienne, au niveau d'une dent ou d'une gencive. Il provoque une douleur vive et se manifeste parfois par d'autres symptômes locaux ou généraux (gêne ou gonflement de la bouche ou du visage, fatigue, fièvre, etc.).

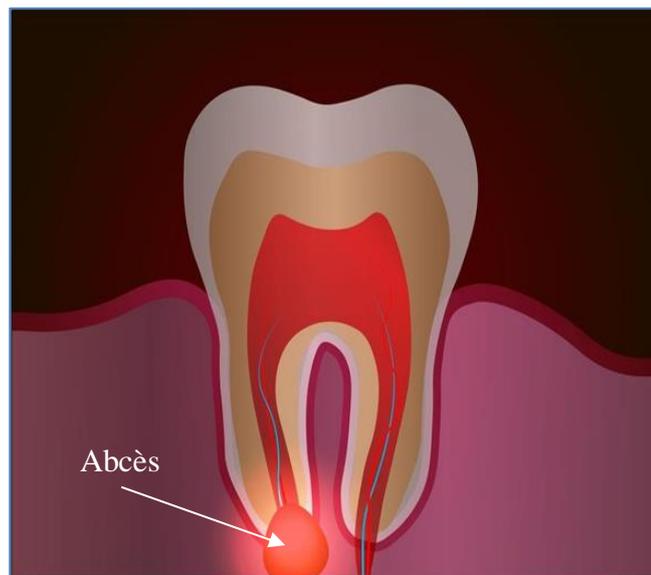


Figure I-7 : Abcès à la base de la racine [7].

❖ Traitement de la carie dentaire :

Le traitement idéal de la carie dentaire comprend la prise de radiographies, l'élimination de la carie par l'emploi d'un foret pneumatique et l'obturation de la cavité pour restaurer la dent. C'est à la fois spécialisé et onéreux.

D'autres méthodes sont envisageables lorsque la situation ou les moyens ne permettent pas de choisir l'option idéale [4].

I.4 Imagerie dentaire pour la détection des caries

Les nettoyages et les examens réguliers font partie des soins bucco-dentaire disponibles au niveau des cabinets dentaires. Cependant, les radiographies dentaires sont aussi couramment utilisées pour détecter les anomalies avant qu'elles ne surviennent et pour diagnostiquer les problèmes existants.

Bien entendu, il existe de nombreux types de radiographies dentaires que le dentiste peut fournir [9]. La Figure I-8 présente les différents types de ces radiographies dentaires.

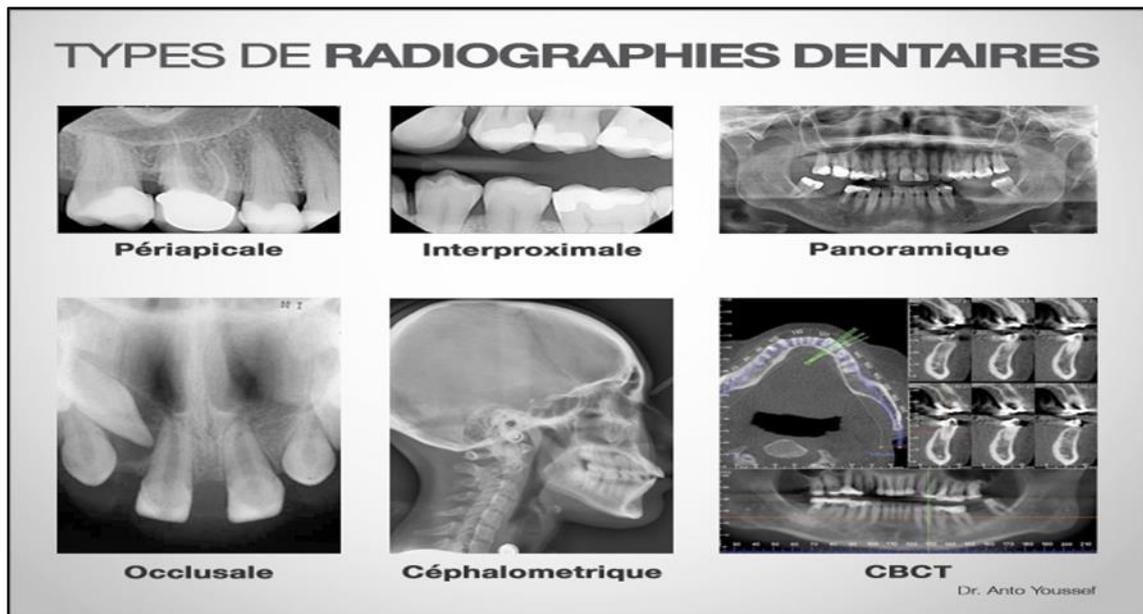


Figure I-8 : Types de radiographies dentaires [11].

I.4.1 Radiographie rétro-coronaire (Bite-Wing)

La radiographie rétro-coronaire ou Bite-wing est très courante et est souvent prise à titre préventif car elle permet de voir toute carie entre les dents ou sous la ligne gingivale (Figure I-9).

Le terme bite-wing vient de la façon dont les patients doivent mordre le film radiographique. Ces types de radiographies peuvent être prises directement sur le fauteuil du dentiste.

Les radiographies dentaires Bite-wing sont aussi couramment utilisées pour localiser la source de la gêne dentaire. De nombreux cabinets dentaires modernes n'utilisent plus de films. Ils utilisent plutôt un capteur, qui envoie la radiographie directement à un ordinateur pour que le dentiste l'examine. Le processus est ainsi plus rapide, car on n'a plus besoin de développer le film [9].

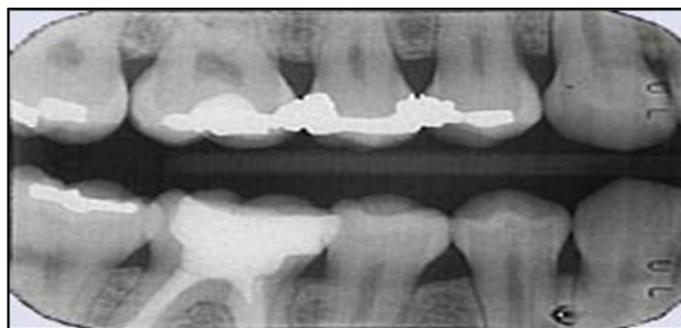


Figure I-9 : Radio Bite-wing [11].

I.4.2 Radiographie périapicale

La radiographie rétro-coronaire montre la plus grande partie de la dent, mais si le dentiste a besoin d'un bon aperçu de la totalité de la dent ou de la mâchoire, une radiographie périapicale est le meilleur choix. Ce type de radiographie dentaire permet de capturer une image de la dent entière, y compris un peu au-delà de la racine de la dent (Voir Figure I-8).

La radiographie capture généralement la totalité de la rangée de dents supérieures ou inférieures en une seule image. Ce type de radiographie peut être utilisé si le dentiste soupçonne un dommage à l'extrémité de la racine de la dent ou un problème au niveau de l'os de la mâchoire [9].

I.4.3 Radiographie occlusale

La radiographie occlusale est conçue pour capter ce qui se passe à l'intérieur du palais ou du plancher de la bouche, ce qui permet au dentiste de voir le développement et la position complète des dents (Voir Figure I-8).

Elle peut être utilisée pour découvrir pourquoi les dents n'ont pas encore fait éruption ou pour repérer les dents surnuméraires (dents en surplus), qui peuvent endommager les dents permanentes saines.

C'est l'un des types de radiographies dentaires qui peut également être utilisé pour diagnostiquer une fente palatine ou une fracture. Les kystes, abcès ou excroissances difficiles à trouver peuvent également être repérés à l'aide d'une radiographie occlusale [9].

I.4.4 Radiographie panoramique

La radiographie panoramique utilise un appareil spécial qui prend une image de toutes les dents supérieures et inférieures. Le résultat est une image en 2-D de la bouche en 3-D. Si le malade souffre de complications fréquentes ou s'il a eu des soins dentaires importants dans le passé, le dentiste peut lui recommander une radiographie panoramique de temps en temps pour s'assurer que rien ne se passe.

Une radiographie panoramique peut être utilisée comme méthode de radiographie courante et est souvent utilisée en préparation de procédures dentaires majeures, telles que l'obtention d'un appareil dentaire (Voir Figure I-8).

De tous les types de radiographies dentaires, les dentistes l'utilisent couramment pour diagnostiquer des complications majeures telles que les tumeurs de la mâchoire, les kystes et les sinusites [9].

I.4.5 Radiographie céphalométrique

Une projection céphalométrique est une radiographie dentaire d'un côté de la tête entière (Voir Figure I-8). Les orthodontistes l'utilisent souvent pour voir comment les dents et les os des mâchoires s'ajustent afin de mieux créer un plan de traitement qui implique toute la bouche.

Le dentiste peut également suggérer ce type de radiographie pour diagnostiquer toute complication de la gorge, telle que des grosseurs ou un cancer. Enfin, si le malade souffre d'apnée du sommeil, les dentistes peuvent souvent l'aider. En effet, il peut d'abord suggérer une radiographie céphalométrique pour voir clairement la structure de la gorge et déterminer la cause de cette apnée du sommeil [9].

I.4.6 Radiographie à faisceau conique (Cone Beam)

Les rayons-X CBCT, "cat-scan" ou "cone beam" sont une méthode d'imagerie qui utilise une technologie informatisée pour convertir des images en deux dimensions en une image en trois dimensions (3D).

Par rapport à une radiographie dentaire bidimensionnelle traditionnelle qui montre une image plane, l'image en 3D montre toutes les dimensions et tous les aspects des dents et de l'os environnant (Voir Figure I-8). Pour le patient, cela signifie un diagnostic précis d'une zone préoccupante qui n'aurait pas été possible sans cette technologie.

De plus, pour les patients qui ont choisi de remplacer des dents manquantes, le dentiste peut examiner, diagnostiquer et placer virtuellement un implant dentaire dans la bouche sur ordinateur devant le malade avant de commencer le traitement.

Cette approche avancée et plus précise utilisant l'imagerie par Cone Beam signifie moins de complications, une thérapie moins invasive, des temps de guérison plus rapides et, au final, de meilleurs résultats pour le patient [9].

I.5 Conclusion

Sans traitement, la carie endommagera la structure de la dent. En progressant, elle peut aller jusqu'à atteindre le cœur de la dent, la pulpe, et présenter ainsi un risque plus important pour l'ensemble de la santé buccale d'une personne.

L'idée qui consiste à penser qu'au fil de la vie, les dents vont être amenées à tomber les unes après les autres, est une image révolue appartenant au passé. Avec une bonne hygiène bucco-dentaire individuelle et de régulières visites chez le chirurgien-dentiste, les principales causes sont évitées grâce aux nouvelles approches thérapeutiques dont nous disposons aujourd'hui.

Chapitre II

État de l'Art

I.1 Introduction

Les caries dentaires sont des maladies bucco-dentaires infectieuses et chroniques courantes. Plusieurs études épidémiologiques et cliniques ont rapporté que la perte de dents est causée par les maladies bucco-dentaires. Ainsi, plusieurs méthodes ont été développées pour la détection et le diagnostic des caries dentaires dans les radiographies péri-apicales.

Dans ce chapitre, nous présentons un état de l'art classifié par ordre chronologique, qui contient les différentes méthodes utilisées pour la détection, l'extraction et la classification de la carie dentaire.

I.2 Méthodes de Détection et de Classification

Nous avons consulté dans notre recherche bibliographique, plusieurs travaux scientifiques portant sur la détection et la classification des caries dentaires.

Nous présentons dans ce qui suit quelques travaux récents qui nous ont semblés intéressants du point de vue de méthodes ou de résultats obtenus.

- **Renee, Vanithamani, et Dhivya 2016 [12]** : Leur travail qui est basé sur le proche infra-rouge (NIR) est une méthode non ionisante et non invasive pour identifier et quantifier les caries à n'importe quel stade, en imagerie dentaire. Cette méthode formée et testée à l'aide du classificateur SVM catégorise la région affectée dans l'image comme normale ou anormale. Les performances du classificateur SVM sont comparées à celles du classificateur SCG-BPN (Scaled Conjugate Gradient - Back Propagation Network) et du classificateur GRN (Generalized Regression Network). La validation des caries à l'aide du classificateur SVM est plus performante que les deux autres classificateurs de la littérature.
- **Albahbah, El-Bakry, et Abdelghany 2016 [13]** : Leur travail présente une stratégie de détection des caries dentaires basée sur un réseau neuronal à rétro-propagation (BP) pour analyser les images radiographiques dentaires. Le réseau neuronal utilise l'autocorrélation inter-pixels comme caractéristiques d'entrée. La précision de la classification était satisfaisante et la détection des

caries dentaires était nettement améliorée par rapport au processus de diagnostic effectué par un programme informatique assisté par règles et un groupe de médecins.

- **Sornam et Prabhakaran 2017 [14]** : Ont proposé une technique améliorée pour l'analyse des caries avec une méthode linéairement adaptative nouvellement générée dans l'optimisation de l'essaim de particules pour le réseau neuronal Feed Forward. Cette technique est concentrée sur l'approche de la classification binaire et cette tentative inductive montre la connotation de l'optimisation adaptative linéaire modifiée de l'essaim de particules, fusionnée avec le réseau neuronal à propagation arrière pour la classification de la bonne dent et de la dent affectée par la carie à partir de la caractéristique extraite d'une image individuelle, en utilisant la matrice de cooccurrence de niveau de gris, pour les images de radiographie dentaire péri-apicale. La technique proposée a permis d'atteindre une précision d'environ 99% avec un taux d'erreur quadratique moyen minimisé d'environ 0.008.
- **Singh et Sehgal 2017 [15]** : Ont proposé un système de détection automatique des caries basé sur la transformation de Radon (RT) et la transformation discrète en cosinus (DCT). La transformation de Radon (RT) est effectuée sur ces images radiographiques pour chaque degré afin de capturer les détails de basse fréquence. Ensuite, la DCT 2-D est appliquée aux images RT pour obtenir les caractéristiques de fréquence (coefficients DCT). Ces caractéristiques sont ensuite converties en vecteur de coefficients 1-D en zigzag, puis soumises à l'analyse en composantes principales (ACP) pour l'extraction des caractéristiques. Enfin, un nombre minimal de caractéristiques est fusionné à l'aide des classificateurs Decision Tree (DT), kNearest Neighbour (k-NN), Random Forest, Naive Bayes, Sequential Minimum Optimization (SMO), Radial Basis Function (RBF), Decision Stumps, AdaBoost pour obtenir les meilleures performances de classification.
- **Prajapati, Nagaraj, et Mitra 2017 [16]** : Ont expérimenté la performance du CNN pour le diagnostic d'un petit ensemble de données dentaires étiquetées.

De plus, l'apprentissage par transfert est utilisé pour améliorer la précision. Les résultats expérimentaux sont présentés pour trois architectures différentes de CNN. La précision globale obtenue est très encourageante.

- **Adel et al. 2018 [17]** : L'objectif principal de cette recherche est d'établir une approche de diagnostic assisté par ordinateur (DAO) pour la détection et la classification de la dysplasie épithéliale orale. Une nouvelle approche a été développée à partir de différentes sélections et grossissements d'images microscopiques colorées. L'analyse résultant de cette recherche permet aux pathologistes de classer les anomalies des cellules. L'approche proposée a atteint une précision de 92,8 % dans la classification de la dysplasie épithéliale orale.

- **Aberin et Goma 2018 [18]** : La méthodologie de cette étude s'est concentrée sur la classification des images microscopiques de la plaque dentaire introduites dans les réseaux neuronaux étaient saines ou non. L'étude actuelle vise également à déterminer si l'architecture AlexNet est le modèle architectural le mieux adapté aux réseaux de neurones convolutifs en donnant un taux de précision acceptable et en concevant un modèle qui pourrait automatiser le processus d'analyse des images microscopiques obtenues. Cette étude a utilisé les réseaux neuronaux convolutifs comme classificateur et a utilisé l'architecture AlexNet pour classer les images, en utilisant Tensorflow. Avec la méthodologie de l'étude actuelle, le modèle a été en mesure de produire un taux de précision de 75,5 %.

- **J.-H. Lee et al. 2018 [19]** : L'objectif de la présente étude était d'évaluer l'efficacité des algorithmes CNN profonds pour la détection et le diagnostic des caries dentaires sur les radiographies péri-apicales. En effet cette étude a mis en évidence l'utilité potentielle de l'architecture CNN profonde pour la détection et le diagnostic des caries dentaires. Avec l'algorithme CNN profond qui a fourni de très bonnes performances dans la détection des caries dentaires sur les radiographies péri-apicales.

- **Yang et al. 2018 [20]** : Leur proposition inclut une méthode automatique avec les connaissances médicales pour recadrer les ROIs pour l'évaluation clinique, les régions apicales adjacentes, et ensuite les paires de ROIs sont introduites dans un CNN pour entraîner le modèle pour l'évaluation automatisée de la qualité clinique. Leur approche obtient un score F1 de 0.749, ce qui est comparable aux performances des dentistes et des radiologues experts.
- **Krois et al. 2019 [21]** : Ils ont appliqué des réseaux de neurones à convolution profonde (CNN) pour détecter la perte osseuse parodontale (PBL) sur des radiographies dentaires panoramiques. Ils ont synthétisé un ensemble de 2001 segments d'images à partir de radiographies panoramiques. Leur test de référence était le pourcentage mesuré de PBL (Periodontal Bone Loss).
- **Kim et al. 2019 [22]** : Dans cette méthode, ils se sont basés sur l'apprentissage profond pour développer un système d'aide au diagnostic automatisé qui détecte la perte osseuse parodontale dans les radiographies dentaires panoramiques. La méthode présentée appelée DeNTNet détecte non seulement les lésions mais fournit également les numéros de dents correspondants de la lésion selon la notation de la fédération dentaire. Cette dernière applique des réseaux de neurones à convolution profonde (CNN) en utilisant l'apprentissage par transfert et les connaissances cliniques préalables pour surmonter la variation morphologique des lésions et un ensemble de données de formation déséquilibré.
- **Schwendicke et al. 2020 [23]** : Ont appliqué des réseaux de neurones à convolution profonde (CNN) pour détecter les lésions carieuses dans les images de transillumination proche infrarouge (NILT).
- **Geetha, Aprameya, et Hinduja 2020 [24]** : Leur travail est basé sur un réseau neuronal de rétropropagation utilisé pour classer une surface dentaire comme normale ou ayant des caries, ils sont utilisés pour former un réseau de neurones artificiels avec une validation croisée de 10 fois et donne une précision de 97.1%.

- **Verma et al. 2020 [25]** : Ont proposé une approche hybride basée sur l'apprentissage profond et l'apprentissage automatique pour détecter des caries dentaires évidentes sur une infection péri-apicale, une altération de la hauteur de l'os parodontal et des impacts de troisième molaire en utilisant des radiographies dentaires panoramiques. Ils ont utilisé un réseau neuronal convolutionnel comme extracteur de caractéristiques pour une image d'entrée et ont utilisé une machine à vecteurs de support pour classer l'image comme "normale" ou "anormale" en fonction des caractéristiques extraites. Puis, ils ont comparé les performances de ce modèle avec celles d'un réseau neuronal à convolution et d'une machine vectorielle de soutien pour la même tâche de classification. Et en comparant également leur meilleur modèle avec d'autres modèles existants formés pour détecter les caries et la perte osseuse parodontale. Les résultats obtenus avec l'approche hybride d'apprentissage profond et d'apprentissage automatique ont surpassé les méthodes existantes dans la littérature.

- **Fukuda et al. 2020 [26]** : Ils ont développé un modèle d'intelligence artificielle pour détecter la fracture verticale d'une dent sur une radiographie panoramique. L'évaluation des performances de ce modèle a révélé un rappel de 75 %, une précision de 93 %, et une mesure F de 83%, montrant ainsi qu'un système de CAD pour la radiographie panoramique a un potentiel d'amélioration.

- **Saini, Jain, et Thakur 2021 [27]** : Ont mis en œuvre le modèle d'apprentissage profond est le réseau de neurones de convolution (CNN). Ils ont formé différents modèles d'apprentissage profond de CNN ; ils sont Visual Geometry Group (Vgg16&Vgg19) Inception-V3 et Resnet50. La formation, la validation et le test ont été effectués sur des ensembles de données binaires avec et sans caries. La précision de la classification est obtenue en utilisant les modèles Vgg16, Vgg19 Inception v3 et Resnet50, et la plus grande précision est obtenue par Inception v3 avec une précision de formation de 99.89% et une

précision de validation de 98,95 avec une perte minimale par rapport aux modèles CNN Vgg16.

- **Singh et Sehgal 2021 [28]** : Ont proposé un nouveau réseau profond de couches de convolution (CNN) avec un modèle de mémoire à long terme (LSTM) pour la détection et le diagnostic des caries dentaires sur des images dentaires péri-apicales. Le classificateur CNN-LSTM optimal proposé avec optimisation de la libellule a classé les images avec une précision de 96 %.
- **Lian et al. 2021 [29]** : Ont fait une étude qui vise à utiliser des méthodes d'apprentissage profond pour détecter les lésions carieuses, classer les différentes extensions radiographiques sur les films panoramiques et comparer les résultats de la classification à ceux des dentistes experts. Avec 1160 films panoramiques dentaires qui ont été évalués par trois dentistes experts. Toutes les lésions carieuses sur les films ont été marquées par des cercles, dont la combinaison a été définie comme l'ensemble de données de référence.
- **Lee et al. 2021 [30]** : Ont développé un modèle CNN utilisant un CNN profond en forme de U (U-Net) pour la détection des caries sur les radiographies interproximales, et ont examiné si ce modèle pouvait améliorer les performances des cliniciens, avec 304 radiographies interproximales qui ont été utilisées pour former le modèle CNN. Les performances de diagnostic étaient les suivantes : précision, 63.29 % ; rappel, 65.02 % ; et score F1, 64.14%, montrant des performances assez précises. Ce modèle peut aider les cliniciens à diagnostiquer les caries dentaires avec plus de précision.
- **Procházka et al. 2022 [31]** : Ont étudié l'efficacité de certaines méthodes mathématiques pour classer les données de réflectivité relevées pour un total de 741 tissus dentaires dans le laboratoire de stomatologie. Les résultats ont montré que le système de réseau neuronal d'apprentissage profond était capable de distinguer les caries des tissus sains sans aucun prétraitement ou sélection

de caractéristiques, avec une meilleure précision que les méthodes standard. La précision de la classification était de 98.1 % et de 94.4 % pour le système d'apprentissage profond utilisant des caractéristiques du domaine du signal et du domaine spectral, respectivement. Le critère de perte était inférieur à 0.01,

- **Imak et al. 2022 [32]** : Ont proposé un nouveau système d'aide à la décision pour le diagnostic automatique des caries dentaires à partir d'images péri-apicales. L'approche proposée est basée sur un modèle d'ensemble de réseau neuronal convolutif profond à entrées multiples (MI-DCNNE). Un ensemble de données d'images péri-apicales couvrant 340 images cariées et non cariées ont été utilisé pour l'évaluation des performances de la méthode proposée. D'après les résultats obtenus, on constate que le modèle proposé est assez performant dans le diagnostic des caries dentaires, le score de précision rapporté étant de 99.13%.

I.3 Tableau récapitulatif

Le tableau ci-dessous résume les principales caractéristiques des différentes méthodes présentées dans les articles consultés ainsi que leurs avantages et inconvénients.

Auteurs et Années	Titres	Base de données	Performances		Architectures	Avantages	Inconvénients
			Mesures	Valeurs			
Renee et al. 2016	Dental Caries Detection Using NIR Imaging Technique.	50: Images 30: Formation 20: Test	Précisions Sensibilité Spécificité	95% 90.9% 100%	SVM SCG_BPN GRN	SVM plus performant.	A développer pour système automatisé de détection des caries.
Albahbah et al. 2016	Detection of Caries in Panoramic Dental X- Ray Images Using Back-Propagation Neural Network.	Non déclarée	Précisions Spécificité	64% 64.91%	ANNs (Artificial Neural Network)	Bons résultats	Difficile de trouver un ensemble de règles pour prendre une décision de diagnostic correct.
Sornam et al. 2017	A New Linear Adaptive Swarm Intelligence Approach Using Back Propagation Neural Network for Dental Caries Classification.	120 images radiographiques péri-apicales.	Précisions	99%	Feed Forward [LA-PSO] [GLCM]	Zéro erreur pour l'ensemble des données d'entraînement.	

Singh et al. 2017	Automates Caries Detection Based on RADON Transformation and DCT.	93 images panoramiques.	Précisions Sensibilité	86% 94%	RT (Transformation de Radon) DCT PCA	Bons résultats. Automatisée et très conviviale.	
Prajapati et al. 2017	Classification of Dental Diseases using CNN and Transfer Learning.	251 images Radiographiques.	Précisions	88,4%	CNN Transfer Learning TL with fine training.	TL donne de bons résultats avec une petite base de données.	L'apprentissage par Transfer peut apprendre des fonctionnalités qui ne sont pas spécifiques.
Adel et al. 2018	Oral Epithelial Dysplasia Computer Aided Diagnostic Approach.	Non déclarée	Précisions	92,8%	SVM Algorithme Surf Algorithme Sift	Résultat le plus élevé de taux en termes de détection de la dyplasie épithétiale orale. Meilleure précision.	
Aberin et	Detecting Periodantal	1000 images	Précisions	75.5%	AlexNet	Modèle le mieux	Erreur quadratique

<p>al. 2018</p>	<p>Disease Using Convolution Neural Networks.</p>	<p>Formation :800 Test:200</p>				<p>adapté utilisant des réseaux de neurons convolutifs. Taux de précision acceptable. modèle qui pourrait automatiser le processus d'analyse des images microscopiques obtenues.</p>	<p>moyenne de 0.5348436995. CNN est très couteux en mémoire, en calcul et en ensemble de donnée.</p>
<p>J.-H. Lee et al. 2018</p>	<p>Detection and Diagnostics of Dental Caries Using a Deep Learning based Convolution Neural Network Algorithm.</p>	<p>3000 images radiographiques Periapicales.</p>	<p>Précisions Sensibilité Spécificité</p>	<p>95% 95% 95%</p>	<p>CNN GoogLeNet Inception V3.</p>	<p>CNN profond donnant des performances bonnes pour la détection des caries dentaires.</p>	<p>Le nombre d'images radiographiques périapicales très petit pour un apprentissage en profondeur conventionnel et</p>

						une précision et une efficacité de détection considérable et un bon diagnostic des caries dentaires.	optimal.
Yang et al. 2018	Automated Dental Image Analysis by Deep Learning on Small Dataset.	196 Images radiographiques Périapicales.	Précisions	82.8%	AlexNet GoogLeNet KNN SVM R F GDBT AdaBoost	Economisation de beaucoup d'efforts manuels sur la préparation des données.	La méthode obtient des résultats considérables lorsqu'il s'agit d'identifier deux classes binaires.
Krois et al. 2019	Deep Learning for the Radiographic Detection of Periodontal Bone Loss.	2001 images radiographies panoramiques	Précision Sensibilité Spécificité	81% 81% 81%	CNN à sept couches.	utile pour la détection de la perte osseuse parodontale sur les radiographies dentaires	Elles ne se généralisent pas bien dans les cas où l'ensemble de données n'est pas suffisamment important, ce qui nécessite une

						panoramiques. Diagnostiques des dentistes peuvent être réduits.	sensibilité élevée.
Kim et al. 2019	Deep Neural Transfer Network for the Detection of Periodontal Bone Loss Using Panoramic Dental Radiographs	800 radiographies	Sensibilité Spécificité	87% 96%	DeNTNet	DeNTNet fournit correctement les chiffres des dents qui sont affectées par la perte osseuse parodontale.	elle détecte uniquement ce problème dentaire.
Schwendicke et al. 2020	Deep Learning for Caries Lesion Detection in Near-Infrared Light Transillumination Images : A Pilot Study.	226 images (113 prémolaires et 113 molaires)	Précision Sensibilité Spécificité Précision Sensibilité Spécificité	69 % 46 % 85 % 68 % 59 % 76 %	Resnet18 Resnext50	Sur un nombre limité d'images a donné une capacité satisfaisante de détecter des lésions caricales	Résultat avec une faible précision.
Geetha et	Dental Caries	105 images	Précision	97,1%	BPNN (Back-	les caries et les	Le système de

al. 2020	Diagnosis in Digital Radiographs Using Back-Propagation Neural Network.	radiographie numérique intra-orale.				Propagation Neural Network)	images normales peuvent être distinguées de façon plus précise par BPNN plutôt que par SVM et KNN.	classement de la profondeur de cavité a besoin d'être amélioré.
Verma et al. 2020	Anomaly detection in panoramic dental x-rays using a hybrid Deep Learning and MachineLearning approach.	250 radiographies panoramiques dentaires. (Normal et caries)	Précision Sensibilité Spécificité	98.69% 97.95% 98.57%	CNN-SVM Architecture hybride	le réseau proposé a obtenu des résultats de pointe en ce qui a trait à l'ensemble des données.	les SVM sont bons pour les tâches de classification, mais doivent avoir des caractéristiques d'entrée étiquetées manuellement qui sont ensuite utilisées pour mapper une entrée à une sortie.	
Fukuda et al. 2020	Evaluation of an artificial intelligence system for detecting	300 images panoramiques	Précisions	93%	DetectNet avec DIGITS version 5.0	Augmentation de la fiabilité du modèle.	Le problème principal qui l'affecte est déterminé.	

	vertical root fracture on panoramic radiography.							
Saini et al. 2021	Dental Caries early Detection using Convolutional Neural Network for Tele dentistry	500 images réelles (caries et sans caries).	Précision Précision	99.89% 99.37%	inception-V 3 VGG net 16	L'application de différents modèles CNN a donné de très bons résultats. Avec une précision élevée obtenue par Inception V3.	Les autres modèles utilisés ont une perte maximale par rapport à Inception V3.	
Singh et al. 2021	Technique de Classification et de Préparation des Caries Dentaires GV Black à l'aide du Classificateur CNN-LSTM Optimal.	1500 images dentaire péri apicale de pour six classes différentes.	Précision	96 %		le modèle CNN-LSTM optimal offre de meilleures performances générales pour Black classification par rapport à	Ce modèle est utilisé comme un deuxième avis et ne peut pas remplacer l'expert médical.	

						d'autres modèles testés sur la même base de données.	
Lian et al. 2021	Deep Learning for Caries Detection and Classification	1160 films panoramiques dentaires	Précision Précision	98.6 % 95.7 %	nnU-Net, (pour détecter) DenseNet121, (pour classer)	Les résultats d'apprentissage profond étaient semblables à ceux des experts dentaires.	L'impact de l'application de ces réseaux neuronaux devrait être étudié en profondeur.
Lee et al. 2021	Deep Learning for Early Dental Caries Detection in Bitewing Radiographs.	304 radiographies bitewing	Précision	63,29%	CNN(U-Net)	modèle d'apprentissage approfondi, aide les cliniciens à détecter les caries avec une plus grande exactitude.	En revanche, ce modèle n'a pas donné un meilleur résultat.
Procházka et al. 2022	Incremental Deep Learning for	741 images radiographies	Précision	98.12 %	CNN-SVM	Cette architecture	Le système d'apprentissage en

	Reflectivity Recognition Stomatology.	Data in	Cas (Sains et Caries).				permet de distinguer les caries dentaires sans pré- traitement ou sélection de caractères avec une plus grande précision que les méthodes standard.	profondeur pour la classification des segments a été en mesure d'éliminer les processus de sélection des caractéristiques du signal, qui peut parfois être assez compliquée et prendre du temps.
Imak et al. 2022	Dental Detection Score-Based Input Convolutional Network.	Caries using Multi- Deep Neural	340 images péri apicales couvrant à la fois des images caries et non caries.	Précision	99.13 %	CNN multi- input modèle MI-DCNNE	Ce résultat montre que ce modèle proposé peut contribuer efficacement à la classification des caries.	La précision est élevée puisque la base de données est conçue selon deux classes.

I.4 Conclusion

Dans ce chapitre nous avons regroupé les différentes méthodes qui ont été utilisées pour détecter et classifier la carie dentaire. Afin de choisir une méthode pertinente qui nous aidera dans notre travail.

D'après les articles que nous avons lus et analysé, nous avons constaté que les réseaux de neurones convolutifs se sont avérés très efficaces pour le traitement de données et dans les domaines tels que la reconnaissance et la classification.

Dans le chapitre suivant, nous allons approfondir et donner plus de détails sur l'algorithme CNN choisi et sur chaque technique en expliquant chaque étape.

Chapitre III

Différentes Méthodes de Classification

III.1 Introduction

Il existe de nombreux types d'algorithmes d'apprentissage automatique ML (Machine Learning). Certains sont plus couramment utilisés que d'autres, comme l'apprentissage supervisé et l'apprentissage non supervisé, et des algorithmes pour les données étiquetées et d'autres pour les données non étiquetées [33].

III.2 L'apprentissage supervisé /non supervisé

Les algorithmes sont les moteurs du machine learning. En général, deux principaux types d'algorithmes de machine learning sont utilisés aujourd'hui : l'apprentissage supervisé et l'apprentissage non supervisé. La différence entre les deux se définit par la méthode employée pour traiter les données afin de faire des prédictions.

III.2.1 L'apprentissage supervisé

Avec l'apprentissage supervisé, la machine peut apprendre à faire une certaine tâche en étudiant des exemples de cette tâche. Par exemple, elle peut apprendre à reconnaître une photo de chien après qu'on lui ait montré des millions de photos de chiens (Figure III-1). Ou bien, elle peut apprendre à traduire le français en chinois après avoir vu des millions d'exemples de traduction français-chinois.

D'une manière générale, la machine peut apprendre une relation qui relie à ??? en ayant analysé des millions d'exemples d'associations [34].

Comme exemples de machine learning supervisé, on peut citer des algorithmes tels que la régression linéaire et logistique, la classification en plusieurs catégories et les machines à vecteurs de support.

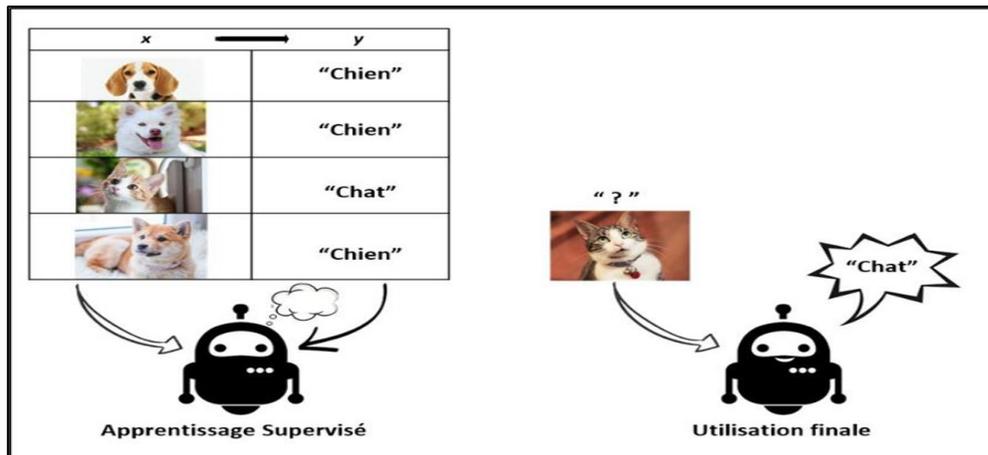


Figure III-1 : Exemple d'apprentissage automatique supervisé [34].

III.2.2 Apprentissage automatique non supervisé

L'apprentissage non supervisé consiste à ne disposer que de données d'entrée (X) et pas de variables de sortie correspondantes (Figure III-2). On l'appelle apprentissage non supervisé car, il n'y a pas de réponse correcte ni d'enseignant [35].

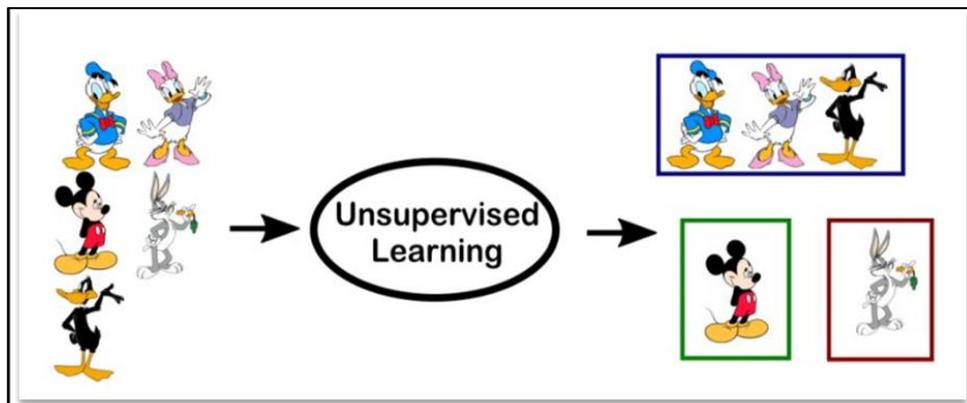


Figure III-2 : Exemple d'apprentissage Automatique non supervisé [35].

Comme exemples d'algorithmes de machine learning non supervisé, on peut citer la mise en cluster de k-moyennes, l'analyse de composants principaux et indépendants, et les règles d'association.

III.3 L'intelligence artificielle en radiologie dentaire

Le nombre de publications scientifiques sur l'utilisation de l'intelligence artificielle (IA) en radiologie dentaire a augmenté ces dernières années. La littérature actuelle présente

des applications potentielles de l'intelligence artificielle, ainsi que des applications cliniques directes dans la pratique de la radiologie des dentistes.

Les principales tâches effectuées par l'IA sont l'amélioration des données radiographiques numériques, l'identification des dents, la détection des lésions radio transparentes, des kystes, des tumeurs, la localisation de repères céphalométriques et le diagnostic de l'ostéoporose en dentisterie panoramique (Figure III-3). Néanmoins, de nombreuses évolutions sont encore nécessaires afin de pouvoir intégrer l'IA dans le travail quotidien au sein du cabinet dentaire [36].



Figure III-3 : Qualité des soins dentaires avec la puissance de l'IA [37].

III.4 Étude comparative des différents algorithmes de l'intelligence artificielle

Il existe plusieurs algorithmes dans le domaine de l'intelligence artificielle, parmi eux :

III.4.1 Support Vector Machines (SVM)

Une machine à vecteurs de support, ou Support Vector Machine (SVM), est un algorithme d'apprentissage automatique supervisé qui peut être utilisé à des fins de classification et de régression. Ils reposent sur l'idée de trouver un hyperplan qui divise au mieux un jeu de données en deux classes, comme le montre la figure ci-dessous [38].

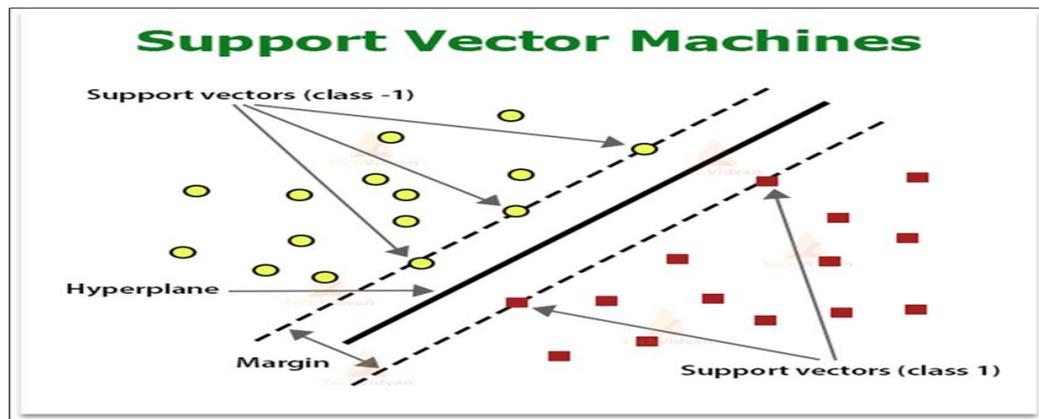


Figure III-4 : Explications de l'SVMs [39].

➤ **Avantages des machines à vecteurs de support**

- leurs grande précision de prédiction.
- Fonctionnent bien sûr de plus petits bases de données.
- Ils peuvent être plus efficaces car ils utilisent un sous-ensemble de points d'entraînement [38].

➤ **Les inconvénients**

- Ne conviennent pas à des jeux de données plus volumineux, car le temps d'entraînement avec les SVM peut être long.
- Moins efficaces sur les jeux de données contenant du bruit et beaucoup de valeurs aberrantes [38].

III.4.2 Arbre de décision

Les algorithmes Decision tree, que l'on appelle également arbres de décision font partie de la catégorie des algorithmes supervisés (Figure III-5). Ils permettent de prédire une valeur (prédiction) ou une catégorie (classement).

C'est une méthode très populaire en science des données (Data Science) et qui a donné naissance à d'autres algorithmes plus puissants tels que Random Forest ou XGBoost par exemple. Comme son nom l'indique, cet algorithme se base sur la construction d'un arbre ce qui rend la méthode assez simple à expliquer et plus facile à interpréter [40].

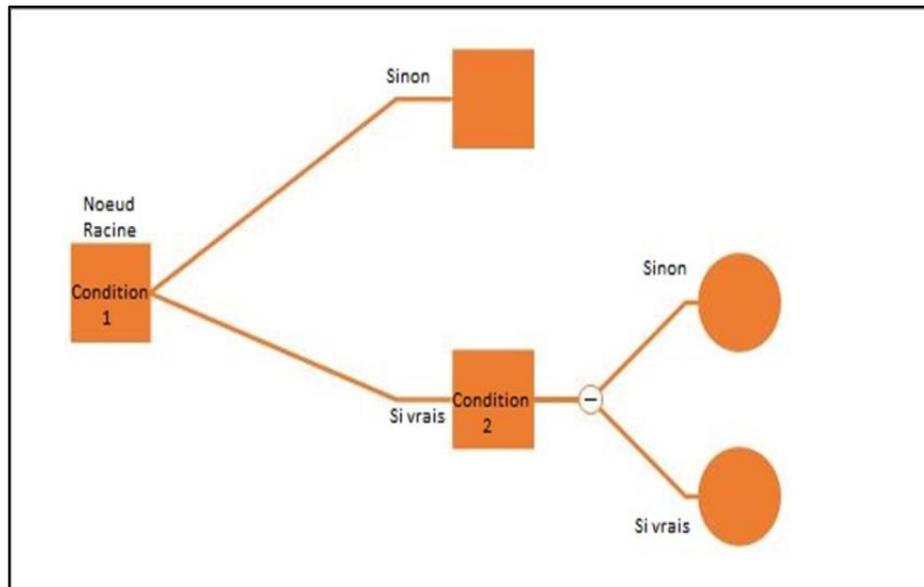


Figure III-5 : Structure de l'arbre de décision [41].

➤ **Avantages des algorithmes à arbre de décision**

- Ils sont vraiment simples à comprendre.
- Ils sont faciles à interpréter.
- C'est un algorithme assez simple qui n'est pas très coûteux en temps de calcul [40].

➤ **Les inconvénients**

- Le manque de performance par rapport à d'autres algorithmes.
- L'over fitting, c'est-à-dire le sur-apprentissage [40].

III.4.3 La régression logistique

La régression logistique est un modèle statistique permettant d'étudier les relations entre un ensemble de variables qualitatives X_i et une variable qualitative Y . Il s'agit d'un modèle linéaire généralisé utilisant une fonction logistique comme fonction de lien.

Un modèle de régression logistique permet aussi de prédire la probabilité qu'un événement arrive (valeur de 1) ou non (valeur de 0) à partir de l'optimisation des coefficients de régression (Figure III-6). Ce résultat varie toujours entre 0 et 1. Lorsque la valeur prédite est supérieure à un seuil, l'événement est susceptible de se produire, alors que lorsque cette valeur est inférieure au même seuil, il ne l'est pas [42].

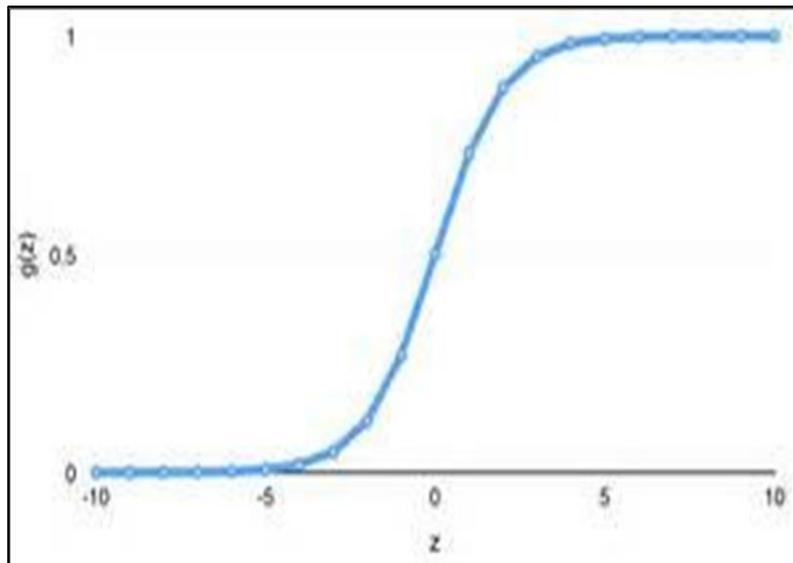


Figure III-6 : Exemple d'une régression logistique [43].

III.4.4 Le Deep Learning

Le Deep Learning appelé apprentissage profond est un sous-ensemble de la machine Learning (Figure III-7) 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 [44].

Un exemple d'application du Deep Learning est la conception des réseaux de neurones à convolution.

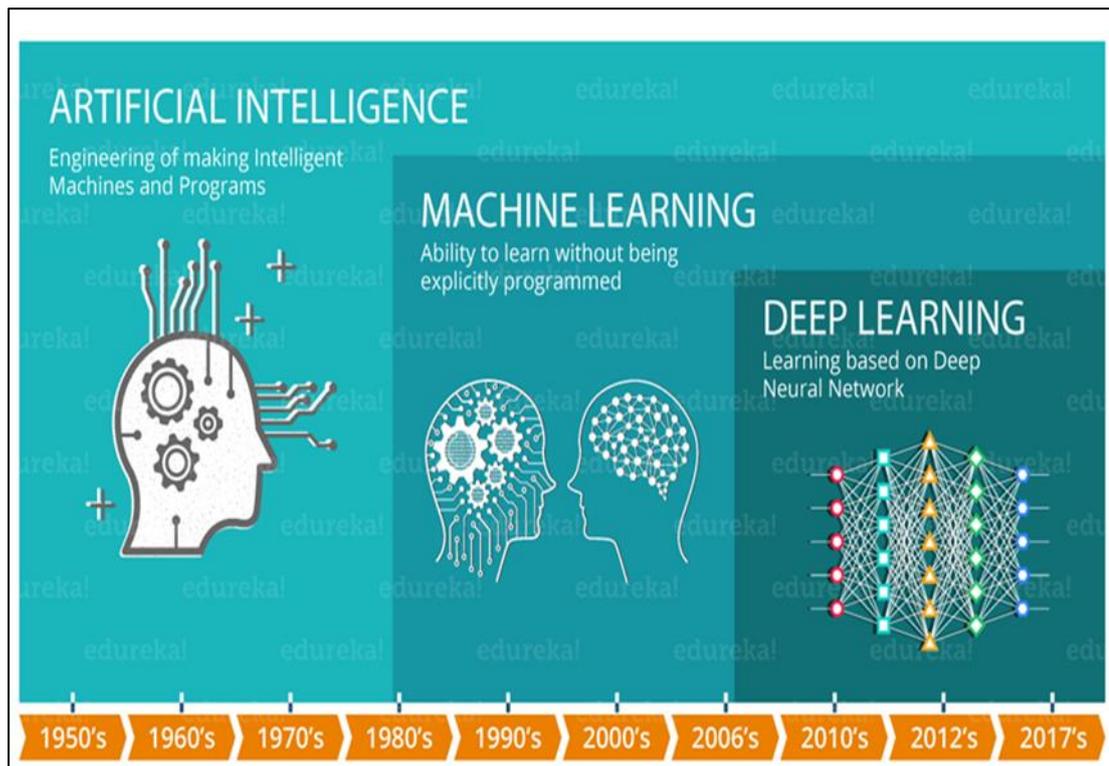


Figure III-7 : La relation entre les 3 domaines [45].

III.4.5 Réseau de Neurones

Pour bien comprendre les réseaux de neurones convolutifs, il est important de connaître les bases des réseaux de neurones. Les principaux éléments à retenir sont les suivants :

- Un réseau de neurones est un système composé de neurones, généralement réparties en plusieurs couches connectées entre elles.
- Un tel système s'utilise pour résoudre divers problèmes statistiques, mais nous nous intéressons ici qu'au problème de classification. Dans ce cas, le réseau calcule à partir de l'entrée un score (ou probabilité) pour chaque classe. La classe attribuée à l'objet en entrée correspond à celle de score le plus élevé.
- Chaque couche reçoit en entrée des données et les renvoie transformées. Pour cela, elle calcule une combinaison linéaire puis applique éventuellement une fonction non linéaire, appelée fonction d'activation. Les coefficients de la combinaison linéaire définissent les paramètres (ou poids) de la couche.
- Un réseau de neurones est construit en empilant les couches : la sortie d'une couche correspond à l'entrée de la suivante.

- Cet empilement de couches définit la sortie finale du réseau comme le résultat d'une fonction différentiable de l'entrée.
- La dernière couche calcule les probabilités finales en utilisant pour fonction d'activation la fonction logistique (classification binaire) ou la fonction softmax (classification multi-classes).
- Une fonction de perte (loss function) est associée à la couche finale pour calculer l'erreur de classification. Il s'agit en général de l'entropie croisée.
- Les valeurs des poids des couches sont apprises par rétropropagation du gradient : on calcule progressivement (pour chaque couche, en partant de la fin du réseau) les paramètres qui minimisent la fonction de perte régularisée. L'optimisation se fait avec une descente du gradient stochastique [46].

III.4.6 Les Réseaux de Neurones Convolutifs

Les réseaux de neurones convolutifs désignent une sous-catégorie de réseaux de neurones : ils présentent donc toutes les caractéristiques listées ci-dessus. Cependant, les CNN sont spécialement conçus pour traiter des images en entrée [46].

Cette architecture est composée de deux blocs principaux :

➤ Le premier Bloc

Il fait la particularité de ce type de réseaux de neurones, puisqu'il fonctionne comme un **extracteur de caractéristiques (*features*)**.

Pour cela, il effectue une correspondance des modèles (*template matching*) en appliquant des opérations de filtrage par convolution. La première couche filtre l'image avec plusieurs noyaux de convolution, et renvoie des cartes caractéristiques (*feature maps*), qui sont ensuite normalisées (avec une fonction d'activation) et/ou redimensionnées [46].

Ce procédé peut être réitéré plusieurs fois : nous filtrons les *cartes caractéristiques* obtenues avec de nouveaux noyaux, ce qui nous donne de nouvelles *cartes caractéristiques* à normaliser et redimensionner, que nous pouvons filtrer à nouveau, et ainsi de suite. Finalement, les dernières valeurs de ces cartes caractéristiques sont concaténées dans un vecteur. Ce dernier définit la sortie du premier bloc et l'entrée du second [46].

➤ Le deuxième Bloc

Il n'est pas une caractéristique d'un CNN mais se retrouve en fait à la fin de tous les réseaux de neurones utilisés pour la classification.

Les valeurs du vecteur en entrée sont transformées (avec plusieurs combinaisons linéaires et fonctions d'activation) pour renvoyer un nouveau vecteur en sortie [46].

Ce dernier vecteur contient autant d'éléments qu'il y a de classes : l'élément représente la probabilité que l'image appartienne à la classe. Chaque élément est donc compris entre 0 et 1, et la somme de tous vaut 1 [46].

Ces probabilités sont calculées par la dernière couche de ce bloc (et donc du réseau), qui utilise une fonction logistique (classification binaire) ou une fonction softmax (classification multi-classes) comme fonction d'activation [46].

Comme pour les réseaux de neurones ordinaires, les paramètres des couches sont déterminés par rétropropagation du gradient : l'entropie croisée est minimisée lors de la phase d'entraînement. Mais dans le cas des CNN, ces paramètres désignent en particulier les caractéristiques des images [46].

La Figure suivante montre les 2 blocs du CNN.

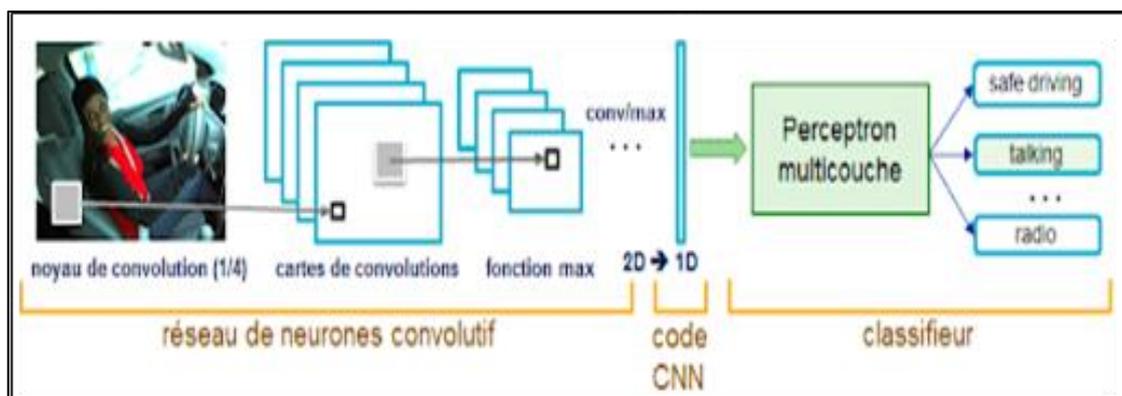


Figure III-8 : Schéma représentant l'architecture d'un CNN [46].

Il existe quatre types de couches pour un réseau de neurones convolutif : la couche de convolution, la couche de pooling, la couche de correction ReLU et la couche fullyconnected [47].

➤ La Couche de Convolution

Elle est la composante clé des réseaux de neurones convolutifs, et constitue toujours au moins leur première couche. Son but est de repérer la présence d'un ensemble de features dans les images reçues en entrée [47].

Pour cela, nous réalisons un filtrage par convolution : le principe est de faire "glisser" une fenêtre représentant la feature sur l'image, et de calculer le produit de convolution entre la

feature et chaque portion de l'image balayée. Une feature est alors vue comme un filtre : les deux termes sont équivalents dans ce contexte [47].

La couche de convolution reçoit donc en entrée plusieurs images, et calcule la convolution de chacune d'entre elles avec chaque filtre. Les filtres correspondent exactement aux features que l'on souhaite retrouver dans les images.

Nous obtenons pour chaque paire (image, filtre) une carte d'activation, ou feature map, qui nous indique où se situent les features dans l'image : plus la valeur est élevée, plus l'endroit correspondant dans l'image ressemble à la feature. Contrairement aux méthodes traditionnelles, les features ne sont pas prédéfinies selon un formalisme particulier, mais apprises par le réseau lors la phase d'entraînement.

Les noyaux des filtres désignent les poids de la couche de convolution et sont initialisés puis mis à jour par rétropropagation du gradient. C'est là toute la force des réseaux de neurones convolutifs : ceux-ci sont capables de déterminer tout seul les éléments discriminants d'une image, en s'adaptant au problème posé. Par exemple, si la question est de distinguer les chats des chiens, les features automatiquement définies peuvent décrire la forme des oreilles ou des pattes [47].

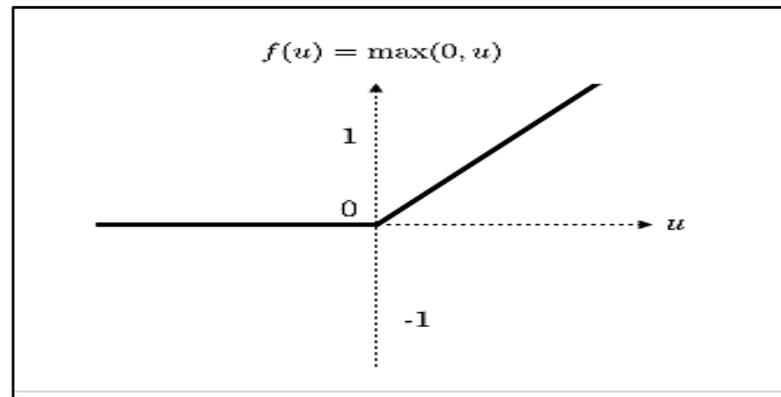
➤ **La couche de pooling**

Ce type de couche est souvent placé entre deux couches de convolution : elle reçoit en entrée plusieurs feature maps, et applique à chacune d'entre elles l'opération de pooling. L'opération de pooling consiste à réduire la taille des images, tout en préservant leurs caractéristiques importantes. Pour cela, nous découpons l'image en cellules régulières, puis nous garde au sein de chaque cellule la valeur maximale. En pratique, nous utilisons souvent des cellules carrées de petite taille pour ne pas perdre trop d'informations. Les choix les plus communs sont des cellules adjacentes de taille 2×2 pixels qui ne se chevauchent pas, ou des cellules de taille 3×3 pixels, distantes les unes des autres d'un pas de 2 pixels (qui se chevauchent donc). Nous obtenons en sortie le même nombre de feature maps qu'en entrée, mais celles-ci sont bien plus petites [47].

La couche de pooling permet de réduire le nombre de paramètres et de calculs dans le réseau. Nous améliorons ainsi l'efficacité du réseau et nous évitons le sur-apprentissage (Overfitting). Les valeurs maximales sont repérées de manière moins exacte dans les feature maps obtenues après pooling que dans celles reçues en entrée [47].

➤ **La couche de correction**

La Couche de Correction ReLU (Rectified Linear Units) désigne la fonction réelle non-linéaire définie par la relation : $\text{ReLU}(x) = \max(0, x)$. La Figure suivante montre la courbe de la couche ReLU :



La couche de correction ReLU remplace donc toutes les valeurs négatives reçues en entrées par des zéros. Elle joue le rôle de fonction d'activation [47].

➤ **La couche entièrement connectée**

La Couche entièrement connectée ou bien la couche fully-connected constitue toujours la dernière couche d'un réseau de neurones, convolutif ou non – elle n'est donc pas une caractéristique d'un CNN. Ce type de couche reçoit un vecteur en entrée et produit un nouveau vecteur en sortie. Pour cela, elle applique une combinaison linéaire puis éventuellement une fonction d'activation aux valeurs reçues en entrée [47].

La dernière couche fully-connected permet de classifier l'image en entrée du réseau : elle renvoie un vecteur de taille NN , où NN est le nombre de classes dans notre problème de classification d'images. Chaque élément du vecteur indique la probabilité pour l'image en entrée d'appartenir à une classe. Chaque valeur du tableau en entrée "vote" en faveur d'une classe. Les votes n'ont pas tous la même importance : la couche leur accorde des poids qui dépendent de l'élément du tableau et de la classe. Pour calculer les probabilités, la couche fully-connected multiplie donc chaque élément en entrée par un poids, fait la somme, puis applique une fonction d'activation (logistique si $N=2$, softmax si $N>2$) [47].

La figure III.9 montre ces différentes couches.

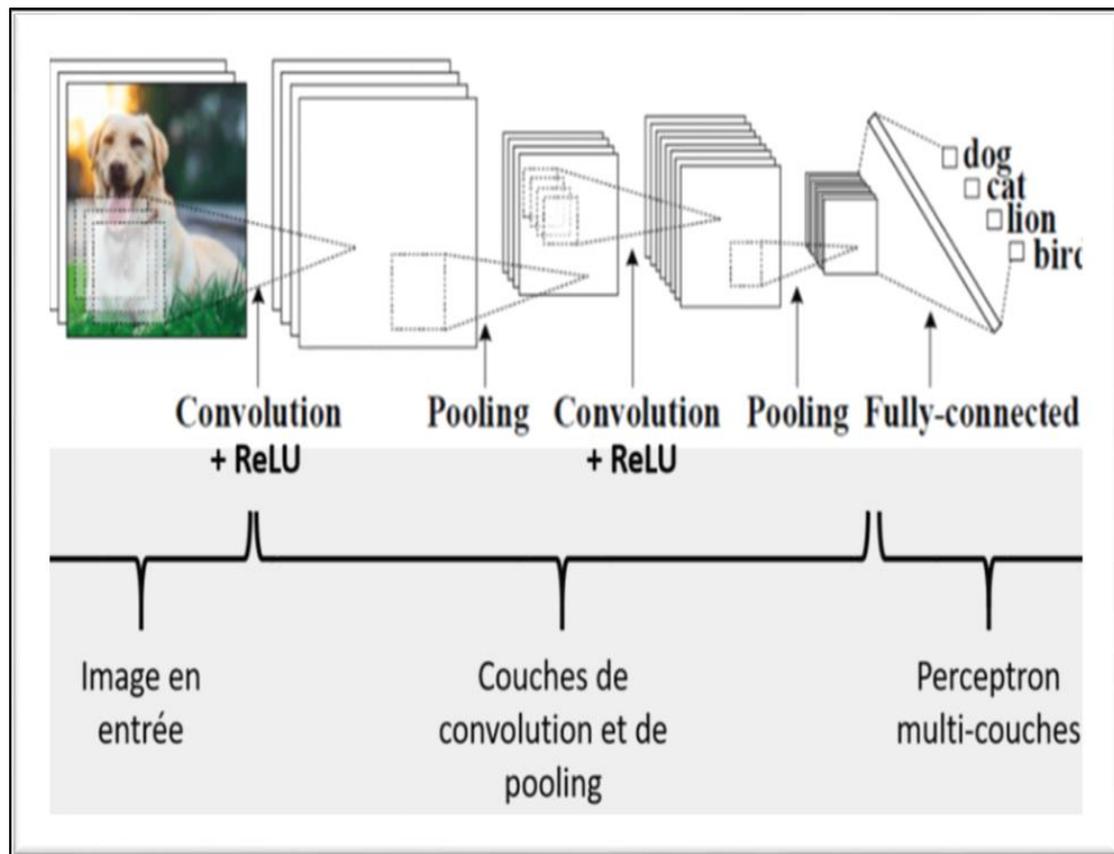


Figure III-9 : Illustration des différentes couches de CNN [48].

III.5 Apprentissage par transfert (Transfer Learning)

Entraîner un réseau de neurones convolutif est très coûteux : plus les couches s'empilent, plus le nombre de convolutions et de paramètres à optimiser est élevé. L'ordinateur doit être en mesure de stocker plusieurs Giga d'octets de données et de faire efficacement les calculs.

C'est pourquoi les fabricants de matériel informatique multiplient les efforts pour fournir des processeurs graphiques (GPU) performants, capables d'entraîner rapidement un réseau de neurones profond en parallélisant les calculs.

Le Transfer Learning (ou apprentissage par transfert) permet de faire du Deep Learning sans avoir besoin d'y passer un mois de calculs. Le principe est d'utiliser les connaissances acquises par un réseau de neurones lors de la résolution d'un problème afin d'en résoudre un autre plus ou moins similaire. Nous réalisons ainsi un transfert de connaissances, d'où le nom.

En plus d'accélérer l'entraînement du réseau, le Transfer Learning permet d'éviter le sur-apprentissage (overfitting). En effet, lorsque la collection d'images en entrée est petite, il

est vivement déconseillé d'entraîner le réseau de neurones en partant de zéro (c'est-à-dire avec une initialisation aléatoire) : le nombre de paramètres à apprendre étant largement supérieur au nombre d'images, le risque d'overfitting est énorme.

Le Transfer Learning est une technique très utilisée en pratique et simple à mettre en œuvre. Elle nécessite d'avoir un réseau de neurones déjà entraîné, de préférence sur un problème proche de celui que nous voulons résoudre.

De nos jours, nous pouvons facilement en récupérant un sur Internet, et notamment dans les bibliothèques de Deep Learning, comme Keras que nous allons utiliser dans notre implémentation.

Nous pouvons exploiter le réseau de neurones pré-entraîné de plusieurs façons, en fonction de la taille du jeu de données en entrée et de sa similarité avec celui utilisé lors du pré-entraînement [49].

Dans cette partie nous allons voir les différents modèles pré-entraînés.

➤ VGG-16

Une version du réseau de neurones convolutif très connu appelé VGG-Net, VGG-16 est constitué de plusieurs couches, dont 13 couches de convolution et 3 *fully-connected*. Il doit donc apprendre les poids de 16 couches [50].

Il prend en entrée une image en couleurs de taille 224 * 224 et la classifie dans une des 1000 classes. Il renvoie donc un vecteur de taille 1000, qui contient les probabilités d'appartenance à chacune des classes.

L'architecture de VGG-16 est illustrée par les figures suivantes (III-10 et III-11) :

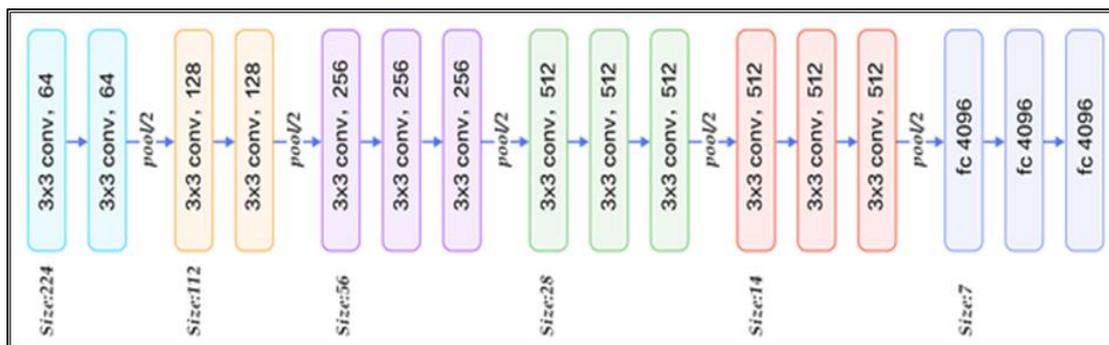


Figure III-10 : Architecture du VGG16 [50].

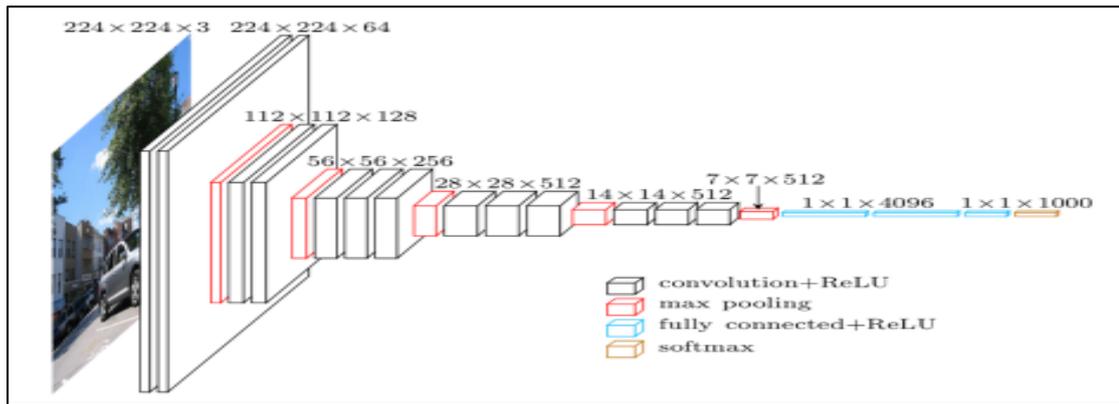


Figure III-11 : Présentation de l'architecture VGG-16 en 3D [50].

Chaque couche de convolution utilise des filtres en couleurs de taille 3×3 , déplacés avec un pas de 1 pixel. Le Remplissage zéro (zero-padding) vaut 1 pixel afin que les volumes en entrée aient les mêmes dimensions en sortie.

Le nombre de filtres varie selon le "bloc" dans lequel la couche se trouve. De plus, un paramètre de biais est introduit dans le produit de convolution pour chaque filtre.

Chaque couche de convolution a pour fonction d'activation une ReLU. Autrement dit, il y a toujours une couche de correction ReLU après une couche de convolution. [50].

➤ VGG19

VGG19 est une variante du modèle VGG qui se compose de 19 couches (16 couches de convolution, 3 couches entièrement connectées, 5 couches MaxPool et 1 couche SoftMax) [50].

L'architecture du VGG19 donnée sur la Figure III-12 est la suivante :

- Une image RVB de taille fixe ($224 * 224$) a été donnée en entrée à ce réseau, ce qui signifie que la matrice était de forme (224, 224, 3) [51]. Le seul prétraitement effectué est de soustraire la valeur RVB moyenne de chaque pixel, calculée sur l'ensemble de l'ensemble d'apprentissage [51]. Des noyaux sont utilisés de taille ($3 * 3$) avec une taille de foulée de 1 pixel, cela leur permet de couvrir toute la notion d'image [51]. Un remplissage spatial est utilisé pour préserver la résolution spatiale de l'image [51].
- Un max pooling est effectué sur une fenêtre de $2 * 2$ pixels avec stride 2. Cela est suivi par l'unité linéaire rectifiée (ReLU) pour introduire la non-linéarité afin de mieux classer le modèle et améliorer le temps de calcul, car les modèles

précédents utilisaient des fonctions tanh ou sigmoïde [51].

- La mise en œuvre de trois couches entièrement connectées dont les deux premières sont de taille 4096 et après cela une couche avec 1000 canaux pour la classification ILSVRC à 1000 voies et la couche finale est une fonction softmax [51].

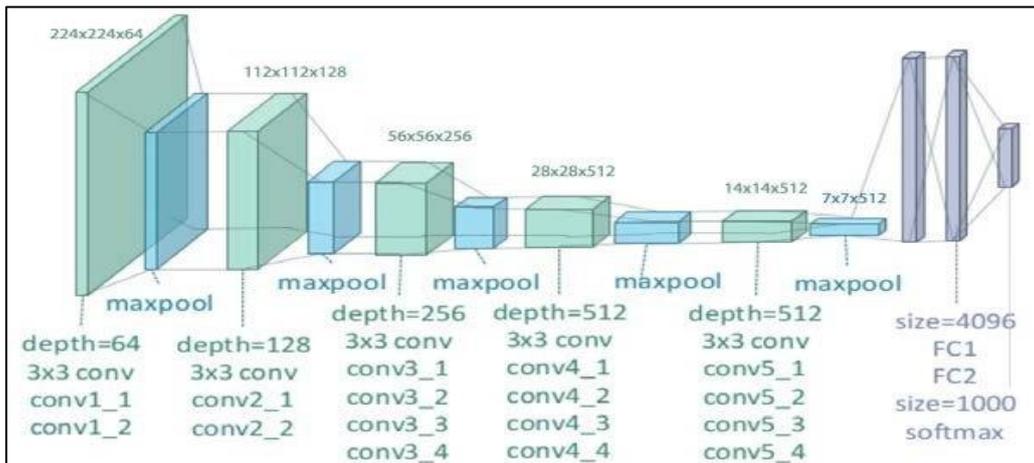


Figure III-12 : Illustration de l'Architecture VGG19 [51].

- Inception-ResNet-V2

Inception -Resnet V2 est un réseau neuronal convolutif entraîné sur plus d'un million d'images de la base de données Imagenet. Le réseau a une profondeur de 164 couches et peut classer les images dans 1000 catégories d'objets, comme le clavier, la souris...etc.

Le réseau a appris des présentations de caractéristiques riches et avec une taille d'entrée d'image de 299* 299[52].

L'architecture d'Inception-ResNet-V2 est présentée dans la figure ci-dessous.

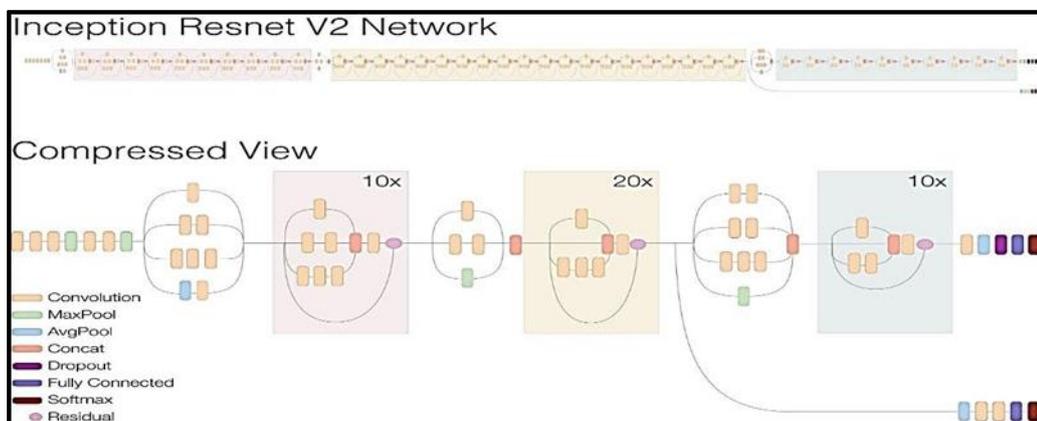


Figure III-13 : Schéma de principe d'Inception-ResNet-v2 [53].

III.6 Paramètres d'évaluation du modèle CNN

Cette partie présente les métriques de performance couramment utilisées dans le Deep Learning et le machine Learning.

L'utilisation des mesures de performance appropriées serait importante pour comparer et identifier le meilleur modèle d'apprentissage automatique pour un problème donné. Pour comprendre les métriques populaires - exactitude, précision, rappel, f1, etc. [54].

➤ Matrice de Confusion

Une matrice de confusion est une table qui est utilisée souvent pour décrire la performance d'un modèle de classification (ou « classificateur ») sur un ensemble de données de test.

Il y a quatre paramètres dans une matrice de confusion : vrai positif, faux positif, faux négatif et vrai négatif.

- Un vrai positif est un résultat où le modèle prédit correctement la classe positive.
- De même, un vrai négatif est un résultat où le modèle prédit correctement la classe négative.
- Un faux positif est un résultat où le modèle prédit de manière incorrecte la classe négative.
- Un faux négatif est un résultat où le modèle prédit de manière incorrecte la classe positive [54].

La figure suivante montre une matrice de confusion.

		True value	
		Positive	Negative
Predicted value	Positive	true positive (tp)	false positive (fp)
	Negative	false negative (fn)	true negative (tn)

Figure III-14 : Matrice de Confusion [54].

➤ **Précision et Accuracy**

- L'accuracy mesure le nombre de données correctement prédites par le modèle (vrai positif + vrai négatif) sur le nombre total de données [54].

$$\text{Accuracy} = \frac{tp+tn}{tp+tn+fp+fn}$$

- La précision mesure le nombre de vrais positifs sur la somme des classes que le modèle a prédites comme positives (vrai positif + faux positif). Cela peut être considéré comme la probabilité que le modèle correctement prédit comme positif soit en fait positif [54].

$$\text{Précision} = \frac{tp}{tp+fp}$$

➤ **Recall (ou Rappel)**

Le recall mesure le nombre de vrais positifs sur la somme des classes positives. Il peut être considéré comme la fraction que le modèle a correctement prédite parmi les classes positives [54].

$$\text{Recall} = \frac{tp}{tp+fn}$$

La précision et le rappel ne considèrent pas le vrai négatif.

Pour obtenir une haute précision, le modèle doit réduire les faux positifs (c'est-à-dire lorsque le modèle prédit à tort comme positif ce qui est en fait une classe négative. Atteindre un rappel élevé serait important dans les applications où la valeur faussement négative devrait être faible, comme le diagnostic de maladie [54].

➤ **Score F_1**

Le score F_1 combine précision et rappel et est défini par la moyenne harmonique de ceux-ci.

Le score F_1 ne prend pas non plus en compte les faux négatifs et est couramment utilisé dans le traitement du langage naturel et les systèmes de recherches d'informations [54].

$$F_1 = 2 \cdot \frac{\text{precision} \cdot \text{recall}}{\text{precision} + \text{recall}} = \frac{2 \cdot \text{TP}}{2 \cdot \text{TP} + \text{FP} + \text{FN}}$$

➤ **ROC**

La courbe ROC (Receiver Operating Characteristic) représente la relation entre le taux de vrais positifs (axe des y) et le taux de faux positifs (axe des x), où :

- Taux de vrais positifs = vrais positifs / (vrais positifs + faux négatifs)
- Taux de faux positifs = faux positif / (faux positif + vrai négatif).

Une bonne courbe ROC aurait un taux de vrais positifs relativement élevé et présenterait une courbe raide où la valeur de l'axe des x est petite [54].

III.7 Conclusion

Le réseau de neurones convolutifs est l'une des techniques d'apprentissage profond les plus utilisées, car il intègre les deux étapes du traitement de l'image.

Les réseaux de neurones convolutifs constituent actuellement les modèles les plus efficaces pour classer les images.

Chapitre IV

Résultats d'Implémentation

IV.1 Introduction

Dans ce chapitre, nous allons exposer les différents outils de notre implémentation. D'abord, nous décrivons la base de données utilisée puis nous donnerons un aperçu sur les environnements et les bibliothèques utilisés pour la programmation. Ensuite, nous allons expliquer les différentes étapes de notre implémentation. Nous allons également commenter les résultats obtenus.

IV.2 Base de Données utilisée

Dans cette étude, on utilise une base de données images obtenues à partir de deux cabinets dentaires privés : Planmeca Intra (Helsinki, Finlande) et MyRay (Imola, Italie).

Cette base contient 340 images péri-apicales en 2D, noir et blanc avec une taille de 227 pixels, Ces radiographies comprennent des images de 150 dents cariées et 190 dents non cariées. Cet ensemble de données a été obtenu sous contrôle par un dentiste.

Le Tableau IV-1 nous montre plus d'informations sur cette base de données [55][32].

Base de données	Nombre d'Image	Format	Le contenu
Caries	150	PNG	Patches de la caries
Normal	190	PNG	Patches des dents saines

Tableau 0-1 : Informations sur la Base de Données.

Les figures suivantes représentent quelques exemples de dents saines et de dents cariées de notre base de données.

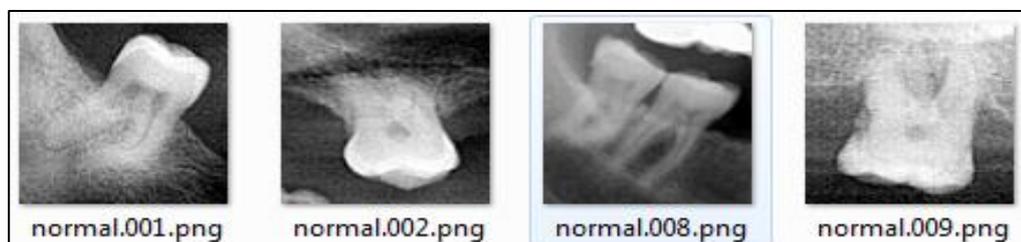


Figure 0-1 : Exemple d'images de dents saines.

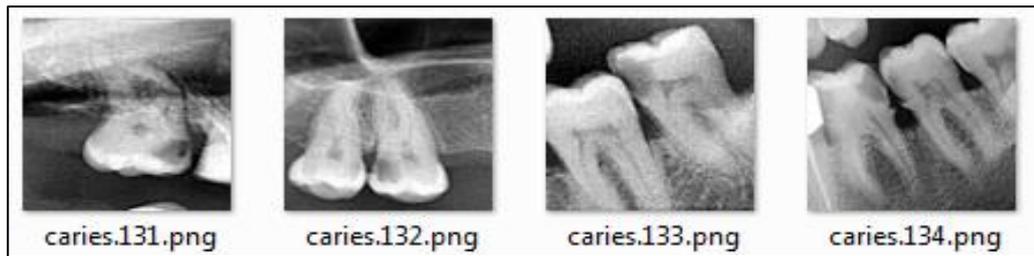


Figure 0-2 : Exemple d'images de caries dentaires.

Remarque : Avec cette base de données, nous avons affronté des problèmes. La base était composée d'images contenant plus d'une dent. Pour cela, on a dû faire une étape de pré traitement d'abord, en utilisant le logiciel ImageJ, qui nous a permis de faire une segmentation manuelle de chaque dent. Ainsi, le nombre d'images de notre base de données a augmenté et est passé à 437 au lieu de 340.

IV.3 Environnement et bibliothèques

Nous avons implémenté notre programme sur un ordinateur portable, avec un processeur Intel® Core™ i5-2410M CPU @ 2.30 GHz, et une mémoire vive de 4.00 Go, sous système d'exploitation Windows 10, 64 bits.

IV.3.1 Google Colaboratory

Colaboratory (Figure IV-3), souvent connu en raccourci par "Colab", nous permet d'écrire et d'exécuter du code Python dans notre navigateur et offre les avantages suivants [56] :

- Aucune configuration requise.
- Accès gratuit aux GPU.
- Partage facile.

Colab permet aussi d'importer un ensemble de données de format images, d'entraîner un classificateur d'images sur cet ensemble et d'évaluer le modèle.

Les notebooks Colab exécutent ce code sur les serveurs cloud de Google. Nous avons donc à notre disposition toute la puissance du matériel Google, y compris les GPU et TPU, quelle que soit la puissance de notre ordinateur. La configuration du Notebook est donnée en Annexe 2.

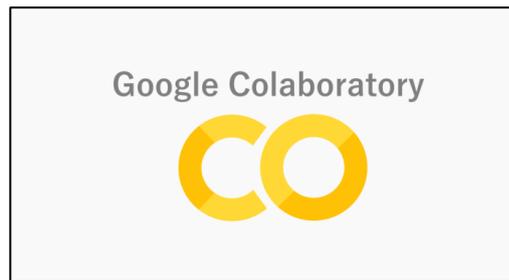


Figure 0-3 : Logo de Colaboratory [56].

IV.3.2 Python

Python (Figure IV-4) est le langage de programmation open source développé par Guido Van Rossum au début des années 1980.

Il est caractérisé par sa polyvalence et est utilisé pour le développement web, l'IA, le Machine Learning, les systèmes d'exploitation, le développement d'applications mobiles, les jeux vidéo et bien d'autres [57].

Il joue un rôle essentiel dans notre cas « Machine Learning », en fournissant des bibliothèques et un ensemble d'outils et de composants logiciels (frameworks), les plus populaires étant Scikit-Learn et TensorFlow [57].



Figure 0-4 : Logo de python [58].

IV.3.3 Tensor Flow

TensorFlow (Figure IV-5) est une plate-forme Open Source dédiée au Machine Learning. Elle propose un écosystème complet et flexible d'outils, de bibliothèques et de ressources communautaires permettant aux chercheurs d'avancer dans le domaine du Machine Learning et aux développeurs de créer et de déployer facilement des applications qui exploitent cette technologie [59].



Figure 0-5 : Logo de Tensor Flow [59].

IV.3.4 Keras

Keras (Figure IV- 6) est une application de programmation (API) de réseaux de neurones de haut niveau, écrite en Python et interfaçable avec TensorFlow, CNTK et Theano.

Elle a été développée avec pour objectif de permettre des expérimentations rapides et d'être capable d'aller de l'idée au résultat avec le plus faible délai possible étant la clef d'une recherche efficace.

Elle propose des API cohérentes et simples qui minimisent le nombre d'actions utilisateur requises pour les cas d'utilisation courants et fournit des messages d'erreur clairs et exploitables. Elle contient également une documentation complète et des guides de développement [60].



Figure 0-6 : Logo de Keras [60].

IV.3.5 Gradio

Gradio est sorti en février 2019 en tant que bibliothèque open source en python pour créer des interfaces utilisateur faciles à utiliser, personnalisables pour tout modèle d'apprentissage automatique ou d'apprentissage profond, ou toute fonction arbitraire [61].

Elle se compose de trois paramètres :

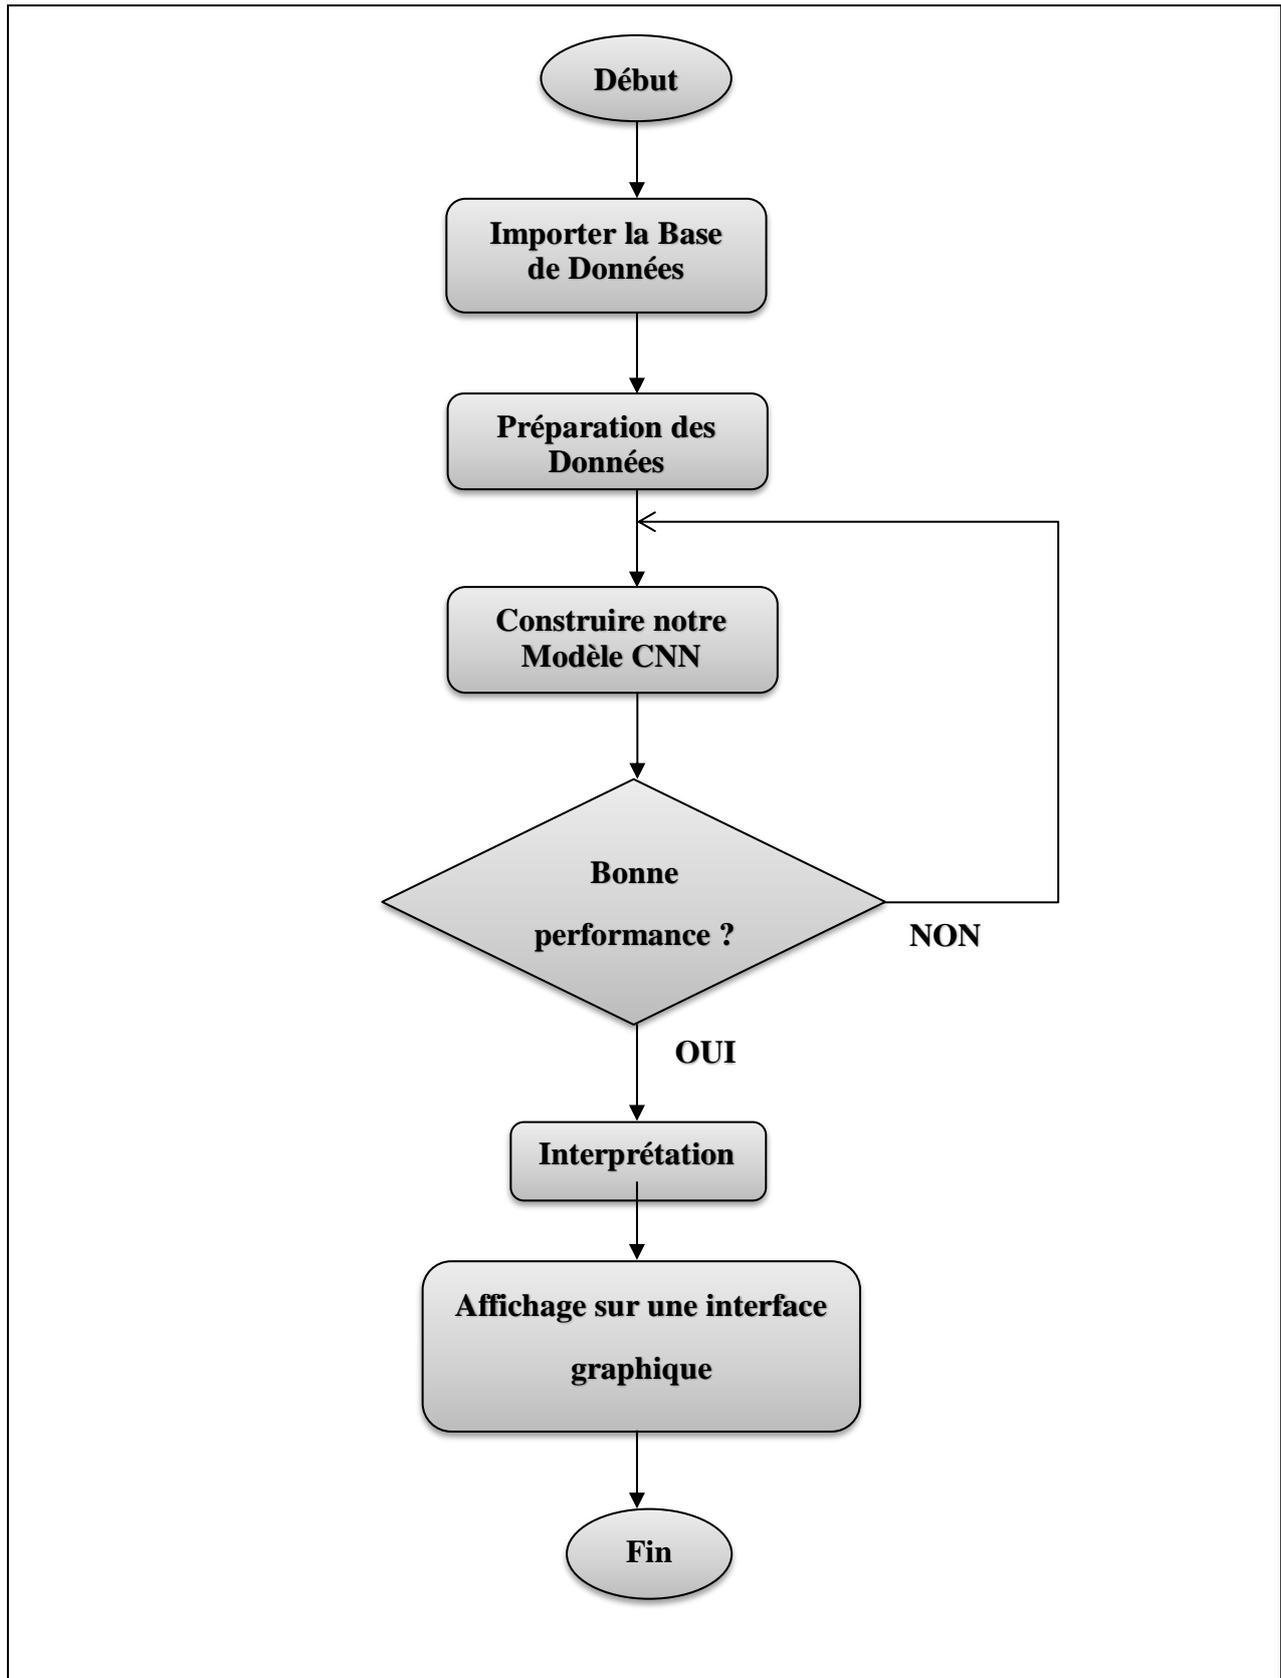
- fn : une fonction qui exécute l'opération principale de l'interface utilisateur.
- Inputs : le type de composant d'entrée.
- Outputs : le type de composant de sortie.

IV.4 Développement de l'Application

Afin de réaliser notre application qui consiste à réaliser la classification d'images dentaires de types péri-apicales en dents saines ou carieuses, nous avons suivi l'organigramme général illustré sur la Figure IV-7.

Une fois que la base données importée et traitée, on procède à la construction du modèle CNN et si les performances recherchées sont bonnes, on procède alors à l'interprétation et à l'affichage du résultat obtenu.

Les différentes étapes représentées sur cet organigramme et suivies dans notre travail pour réaliser la classification seront développées dans le prochain point.

**Figure 0-7** : Organigramme Général.

IV.4.1 Méthodologie de programmation suivie

Nous allons travailler sur une classification binaire de la carie dentaire. Notre but étant de classer une dent saine d'une dent carieuse.

Nous avons développé notre programme en suivant les différents processus suivants :

Étape 1: Importation des Bibliothèques et des couches nécessaires

Nous commençons par préparer notre environnement en important les bibliothèques et les couches nécessaires.

Pour notre cas, comme nous utilisons le framework TensorFlow, nous allons importer la bibliothèque Keras ainsi que d'autres bibliothèques importantes telles que :

- Matplotlib : une bibliothèque complète pour créer des visualisations statiques animées et interactives en Python.
- Numpy : permet d'effectuer des calculs numériques avec Python.
- Sklearn.model_selection: Pour utiliser le programme train_test_split pour estimer les performances des algorithmes d'apprentissage.
- ImageDataGenerator pour le pré-traitement des images.
- Sklearn.metrics : Pour évaluer notre modèle en voyant la matrice de confusion, le F1 score, la précision et l'Accuracy.
- Couches spécifiques à CNN telles que Dropout, Flatten, Activation, Conv2D, MaxPooling2D, BatchNormalisation.

➤ Le code source de cette partie est donné en Annexe 1.

Étape 2: Importation de la Base de Données utilisée

Nous avons choisi une base de données pour cette tâche, qui se compose de deux classes :

- Caries.
- Normal.

Étape 3: Préparation des Données

Maintenant que nous avons la base de données, nous avons transformé cet ensemble de données en données d'entraînement.

➤ Définition des paramètres

Nous avons défini 4 variables :

- DATADIR : c'est le dossier où se trouvent nos images.

```
DATADIR = "/content/drive/MyDrive/data_teeth"
```

- CATEGORIES : qui correspond aux sous dossiers (les classes).

```
CATEGORIES = ["caries", "normal"]
```

Remarque : les catégories vont être numériques : 0 pour «Caries» et 1 pour «Normal». L'ordre est très important, nous avons commencé par « Caries » donc nous allons lui attribuer la valeur 0.

- IMG_SIZE : qui correspond à la taille d'image.

```
IMG_SIZE = 227
```

- Nous avons créé une variable training_data dans laquelle nous avons stocké le résultat de ce que nous allons faire avec nos images.

```
training_data=[]
```

➤ Création du Dataset

- Nous avons indexé nos classes : 0 pour « Caries » et 1 pour « Normal ».

```
class_num = CATEGORIES.index(category) # get the classification
```

- Il est à noter que toutes les images sans exception sont parcourues dans notre Base de données.
- Ces dernières sont transformées en tableaux et stockés sous forme matricielle.
- Toutes les images sont redimensionnées en même temps.
- Une fois que nous avons fait ça, On rajoute le tout dans la variable training_data.

- Puis nous avons lancé la fonction `training_data`, l'ensemble des informations de nos images sera affiché

```
100% |██████████| 150/150 [00:01<00:00, 104.23it/s]
100% |██████████| 190/190 [00:01<00:00, 109.99it/s]
```

➤ Vérification des Données importées

La figure suivante nous montre une image de notre base de données avec l'étiquette « Caries » et de taille (227,227).

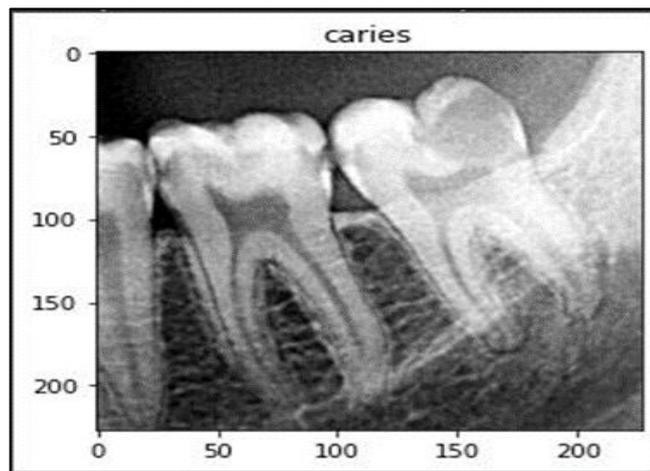


Figure 0-8 : Une image de notre base de données.

➤ Séparation des données

Nous avons divisé nos données en 3 parties :

- Test 30%
- Apprentissage (Train) 60 %
- Validation 10%

➤ Augmentation des Données

Pour une meilleure performance, nous avons augmenté nos données en utilisant des fonctions telles que la rotation. Ainsi, le nombre d'images de la base de données est passé de 437 à 650.

Étape 4: L'architecture de notre modèle CNN

Au cours de notre travail, nous avons créé deux modèles : le modèle 1 basé sur une architecture simple de CNN et le modèle 2 basé sur la méthode d'apprentissage par transfert.

Ces 2 modèles ont été testés avec différentes architectures.

➤ Modèle 1 :

Pour résoudre notre problème de classification, on a utilisé un modèle composé de couches de convolution connu sous le nom de réseau de neurones convolutifs, (Convolutional Neural Network (CNN)).

Dans notre réseau, on a appliqué 2 couches de convolution avec les caractéristiques suivantes :

❖ Paramètres de la 1^{ère} couche :

- ✓ 32 filtres.
- ✓ Un motif de taille (3, 3), aussi appelé kernel 3×3 pixels.
- ✓ Une fonction d'activation (Relu).

Cette couche passe sur chaque pixel de l'image, pour en extraire des motifs de taille 3×3 pixels (kernel = (3,3)). La couche exécute cette action 32 fois (filtres = 32).

❖ Paramètres de la 2^{ème} couche :

- ✓ 64 filtres.
- ✓ Un motif de taille (3, 3), aussi appelé kernel 3×3 pixels.
- ✓ Une fonction d'activation (Relu).

Une couche de convolution retourne un 3D-tensor, un tenseur à 3 dimensions, ce ne peut donc pas être la couche finale.

On utilise alors une couche appelée *Flatten* qui permet d'**aplatir le tenseur**, de réduire sa dimension. Elle prend **en entrée un 3D-tensor et retourne un 1D-tensor**.

Dans la dernière couche, on a utilisé la fonction **sigmoïde**, c'est une fonction d'activation qui pour les petites valeurs (< 5) renvoie une valeur proche de zéro, et pour les grandes valeurs (>5) , le résultat de la fonction se rapproche de 1. Donc la fonction sigmoïde renvoie toujours une valeur comprise entre 0 et 1.

Le Tableau IV-2 présente les différents paramètres utilisés pour entraîner notre modèle.

Paramètres	Propriétés
Batch Size	32
Input Shape	227*227
Epoch	100
Loss	Binary_crossentropy
Early stopping	24

Tableau 0-2 : Les Paramètres utilisés pour la Phase d'Apprentissage "Modèle 1".

Il existe plusieurs optimiseurs en apprentissage profond, parmi lesquels (SGD, Adamax, Adadelta ect...) Dans notre travail nous utilisons l'optimisation d'Adam, car il est :

- Simple à mettre en œuvre.
- Efficace en termes de calcul.
- Peu de besoins en mémoire.

Le Tableau IV-3 présente l'optimisateur que nous avons utilisé.

Hyper Paramètres	Taux d'apprentissage
Optimisateur Adam	0.001

Tableau 0-3 : L'optimisateur Adam.

La Figure IV-9 montre les couches utilisées, leur taille de sortie ainsi que le nombre total des paramètres entraînés.

```

Model: "sequential"
-----
Layer (type)                Output Shape                Param #
-----
conv2d (Conv2D)             (None, 225, 225, 32)      896
conv2d_1 (Conv2D)           (None, 223, 223, 64)     18496
flatten (Flatten)           (None, 3182656)           0
dense (Dense)               (None, 1)                  3182657
-----
Total params: 3,202,049
Trainable params: 3,202,049
Non-trainable params: 0
-----
Number of trainable weights before freezing the conv base: 6
Number of trainable weights after freezing the conv base: 6

```

Figure 0-9 : Configuration du "Modèle 1".

➤ **Modèle 2 :**

Dans ce modèle, nous avons fait appel à l'apprentissage par transfert (Extraction des caractéristiques) en utilisant le modèle pré-entraîné VGG-16 (16 couches) tout en fixant les paramètres nécessaires et en choisissant les deux dernières couches (Couches 14 et 15) de type fully-connected.

Ainsi, on a créé deux couches fully-connected composées chacune de 64 neurones où la fonction d'activation utilisée est le ReLU pour la couche N°14 et la fonction sigmoid pour la couche N°15.

Le Tableau IV-4 présente les différents paramètres utilisés pour entraîner notre modèle.

Paramètres	Propriétés
Batch Size	32
Input Shape	224*224
Epoch	100
Loss	Binary_crossentropy
Early stopping	41

Tableau 0-4 : Paramètres utilisés pour la phase d'apprentissage (Modèle 2).

Le Tableau IV-5 présente l'optimisateur que nous avons utilisé.

Hyper Paramètres Optimisateur	Taux d'apprentissage
Adam	0.001

Tableau 0-5 : L'optimisateur Adam.

La Figure IV-10 montre les couches utilisées, leur taille de sortie ainsi que le nombre total des paramètres entraînés.

```

58900480/58889256 [=====] - 0s 0us/step
Model: "model"

```

Layer (type)	Output Shape	Param #
input_1 (InputLayer)	[(None, 224, 224, 3)]	0
block1_conv1 (Conv2D)	(None, 224, 224, 64)	1792
block1_conv2 (Conv2D)	(None, 224, 224, 64)	36928
block1_pool (MaxPooling2D)	(None, 112, 112, 64)	0
block2_conv1 (Conv2D)	(None, 112, 112, 128)	73856
block2_conv2 (Conv2D)	(None, 112, 112, 128)	147584
block2_pool (MaxPooling2D)	(None, 56, 56, 128)	0
block3_conv1 (Conv2D)	(None, 56, 56, 256)	295168
block3_conv2 (Conv2D)	(None, 56, 56, 256)	590080
block3_conv3 (Conv2D)	(None, 56, 56, 256)	590080
block3_pool (MaxPooling2D)	(None, 28, 28, 256)	0
block4_conv1 (Conv2D)	(None, 28, 28, 512)	1180160
block4_conv2 (Conv2D)	(None, 28, 28, 512)	2359808
block4_conv3 (Conv2D)	(None, 28, 28, 512)	2359808
block4_pool (MaxPooling2D)	(None, 14, 14, 512)	0
block5_conv1 (Conv2D)	(None, 14, 14, 512)	2359808
block5_conv2 (Conv2D)	(None, 14, 14, 512)	2359808
block5_conv3 (Conv2D)	(None, 14, 14, 512)	2359808
block5_pool (MaxPooling2D)	(None, 7, 7, 512)	0
flatten (Flatten)	(None, 25088)	0
dense (Dense)	(None, 64)	1605696
dropout (Dropout)	(None, 64)	0
dense_1 (Dense)	(None, 1)	65

```

=====
Total params: 16,320,449
Trainable params: 1,605,761
Non-trainable params: 14,714,688
=====
Number of trainable weights before freezing the conv base: 4
Number of trainable weights after freezing the conv base: 4

```

Figure 0-10 : Configuration du "Modèle 2".

IV.4.2 Résultats et interprétation

Après avoir terminé les étapes nécessaires pour construire un système de classification, passons maintenant à l'évaluation des 2 modèles précédents :

➤ **Modèle 1 :**

Les deux graphes présentés sur la Figure IV-11 indiquent la variation des données d'apprentissage par rapports aux données de validation en fonction des époques pour le processus d'apprentissage.

La précision d'entraînement commence par une valeur minimale proche de 0.2 et celle de validation à une valeur de 0,76. Les valeurs de précision pour les données d'apprentissage et celles de validation se rapprochent. Puis ces dernières augmentent progressivement jusqu'à l'Epoch 24, où chacune d'elles atteint sa meilleure valeur, ceci reflète qu'à chaque Epoch le modèle apprend plus d'informations.

- ✓ Précision d'entraînement : 0,99 à l'Epoch 24.
- ✓ Précision de validation : 0,93 à l'Epoch 24.

L'erreur d'entraînement commence par une valeur maximale de 0.48 et celle de la validation à une valeur de 0,6. Les valeurs de l'erreur pour les données d'apprentissage et celles de validation se rapprochent. Puis ces dernières diminuent progressivement jusqu'à l'époque 24, où chacune d'elles atteint sa meilleure valeur.

- ✓ Erreur d'entraînement : 0.001 à l'époque 24.
- ✓ Erreur de validation : 0,3 à l'époque 24.

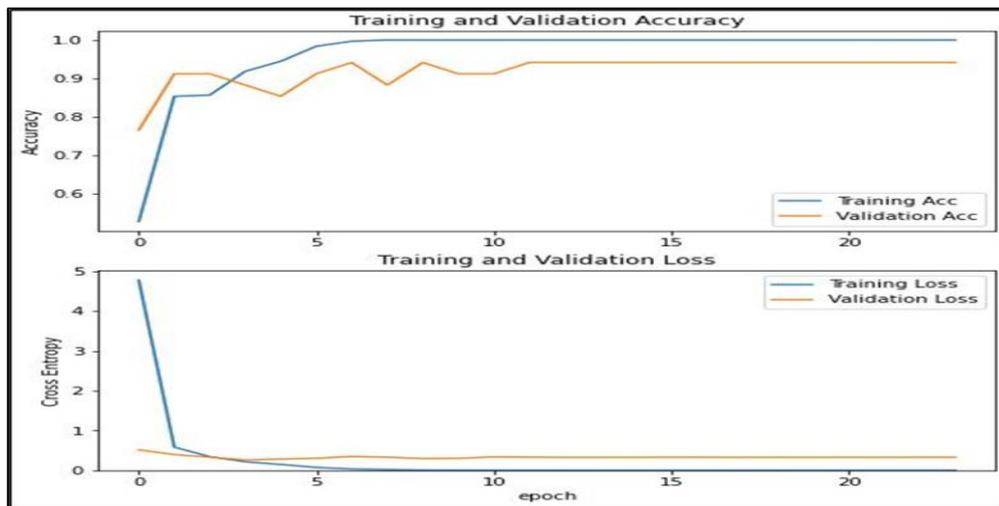


Figure 0-11 : Résultats de la phase d'apprentissage "Modèle 1".

La Figure IV-12 montre la précision et l'erreur obtenue dans chaque phase : apprentissage, test et validation.

```

loss, accuracy = model.evaluate(X_test, y_test)
loss, accuracy = model.evaluate(X_val, y_val)
loss, accuracy = model.evaluate(X_train, y_train)

4/4 [=====] - 0s 105ms/step - loss: 0.0868 - acc: 0.9902
2/2 [=====] - 0s 10ms/step - loss: 0.3268 - acc: 0.9412
10/10 [=====] - 0s 39ms/step - loss: 2.0140e-04 - acc: 1.0000

```

Figure 0-12 : L'évaluation du "Modèle 1".

Nous avons testé la performance de notre modèle par une image qui a été choisie aléatoirement par le système. La Figure IV-13 montre la prédiction obtenue.

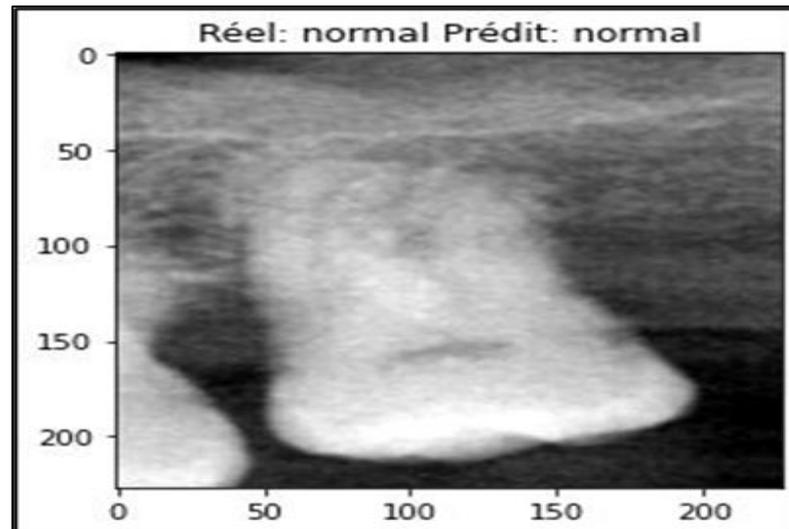


Figure 0-13 : Exemple d'un résultat de prédiction "Modèle 1".

La Figure IV-14 montre la matrice de confusion de notre modèle séquentiel.

```
[[46  0]
 [ 1 55]]
```

Figure 0-14 : Matrice de confusion "Modèle1".

Nous avons testé notre ensemble de données sur 102 images. D'après la matrice de confusion ci- dessous, nous avons :

- ✓ Dans la classe Carie : toutes les prédictions sont correctes.
- ✓ Dans la classe Normal : Le modèle à prédit 1 fois un résultat faux et 55 fois que la classe est correcte.

	Carie	Normal
Carie	46	0
Normal	1	55

➤ **Model 2 :**

Les deux graphes présentés sur la Figure IV-15 indiquent la variation des données d'apprentissage par rapports aux données de validation en fonction des Epoch pour le processus d'apprentissage.

La précision d'entraînement commence par une valeur minimale proche de 0.51 et celle de validation à une valeur de 0,53. Cette différence est due à l'utilisation de la méthode d'apprentissage par transfert.

Les valeurs de précision pour les données d'apprentissage et celles de validation se rapprochent. Puis ces dernières augmentent progressivement jusqu'à l'Epoch 41, où chacune d'elles atteint sa meilleure valeur, ceci reflète qu'à chaque Epoch le modèle apprend plus d'informations.

- ✓ Précision d'entraînement : 0,98 à l'Epoch 37.
- ✓ Précision de validation : 0,93 à l'Epoch 33.

L'erreur d'entraînement commence par une valeur maximale de 1.3 et celle de la validation à une valeur de 0,7.

Les valeurs de l'erreur pour les données d'apprentissage et celles de validation se rapprochent. Puis ces dernières diminuent progressivement jusqu'à l'Epoch 44, où chacune d'elles atteint sa meilleure valeur.

- ✓ Erreur d'entraînement : 0.02 à l' Epoch 33.
- ✓ Erreur de validation : 0,22 à l'Epoch 30.

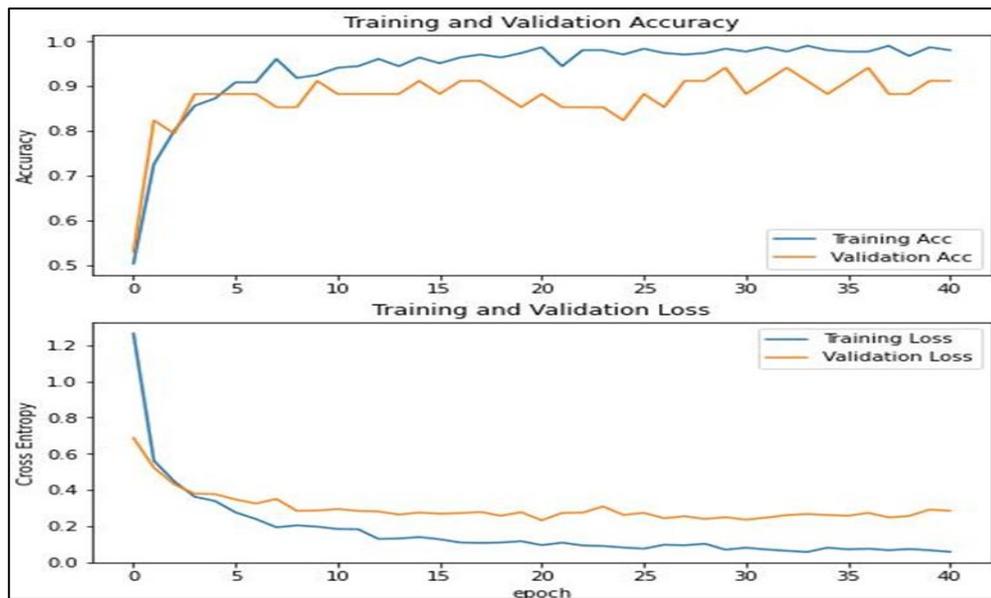


Figure 0-15 : Résultat de la phase d'apprentissage "Modèle 2".

La Figure IV-16 montre la précision et l'erreur obtenue dans chaque phase apprentissage, test et validation.

```

loss, accuracy = model.evaluate(X_test, y_test)
loss, accuracy = model.evaluate(X_val, y_val)
loss, accuracy = model.evaluate(X_train, y_train)

4/4 [=====] - 2s 452ms/step - loss: 0.1039 - acc: 0.9902
2/2 [=====] - 0s 27ms/step - loss: 0.2079 - acc: 0.9706
10/10 [=====] - 2s 155ms/step - loss: 0.0470 - acc: 1.0000

```

Figure 0-16 : L'évaluation du "Modèle 2".

Nous avons testé la performance de notre modèle par une image qui a été choisie aléatoirement par le système. La Figure IV-17 montre la prédiction obtenue.

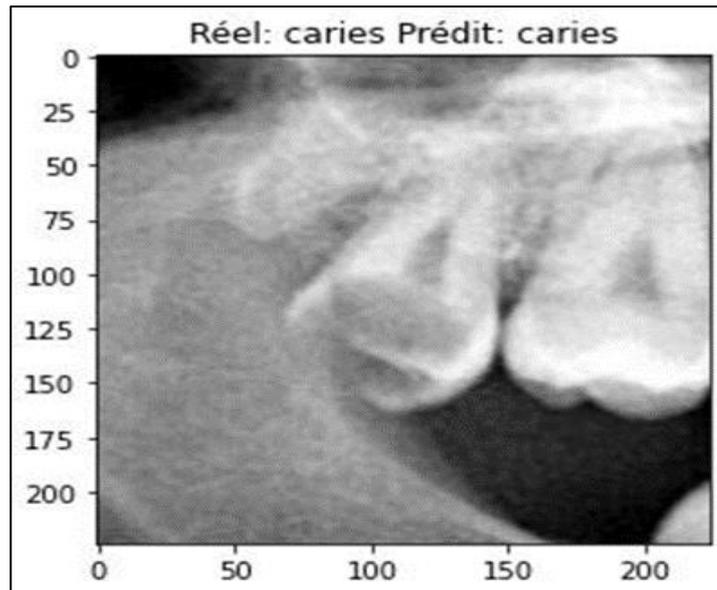


Figure 0-17 : Exemple d'un résultat de prédiction "Modèle 2".

La Figure IV-18 montre la matrice de confusion de notre modèle VGG16.

```
[[45  1]
 [ 1 55]]
```

Figure 0-18 : Matrice de confusion "Modèle 2".

Nous avons testé notre ensemble de données sur 102 images. D'après la matrice de confusion ci- dessous, nous avons.

- ✓ Dans la classe Carie : Le modèle à prédit 1 fois un résultat faux et 45 fois que la classe est correcte.
- ✓ Dans la classe Normal : Le modèle à prédit 1 fois un résultat faux et 55 fois que la classe est correcte.

	Carie	Normal
Carie	45	1
Normal	1	55

Le Tableau IV-6 suivant montre la comparaison entre les deux modèles que nous avons étudiés.

	Base de données utilisée	Architecture utilisée	Nombre d'Epoch	Validation Accuracy	Test Accuracy	Loss	Temps d'exécution
Modèle 1	Data_teeth	Séquentielle	24	94.12%	99.02%	03.2 %	10 s
Modèle 2	Data_teeth	VGG-16	41	97.06%	99.02%	0.20 %	1 min 31 s

Tableau 0-6 : Tableau comparatif des deux Modèles réalisés.

IV.5 Développement d'une interface graphique

Afin de permettre aux praticiens d'exploiter nos résultats, nous avons procédé au développement d'une interface graphique simple à utiliser.

Pour cela, nous avons développé sous Python un programme qui permet de convertir le code Deep Learning développé auparavant (modèle 2) en une application Web grâce à Gradio pour avoir une interface souple et simple à utiliser.

- L'installation de Gradio et les bibliothèques utilisées sont présentées dans l'annexe 3.
- La Figure IV-19 montre l'interface obtenue de notre application Web.

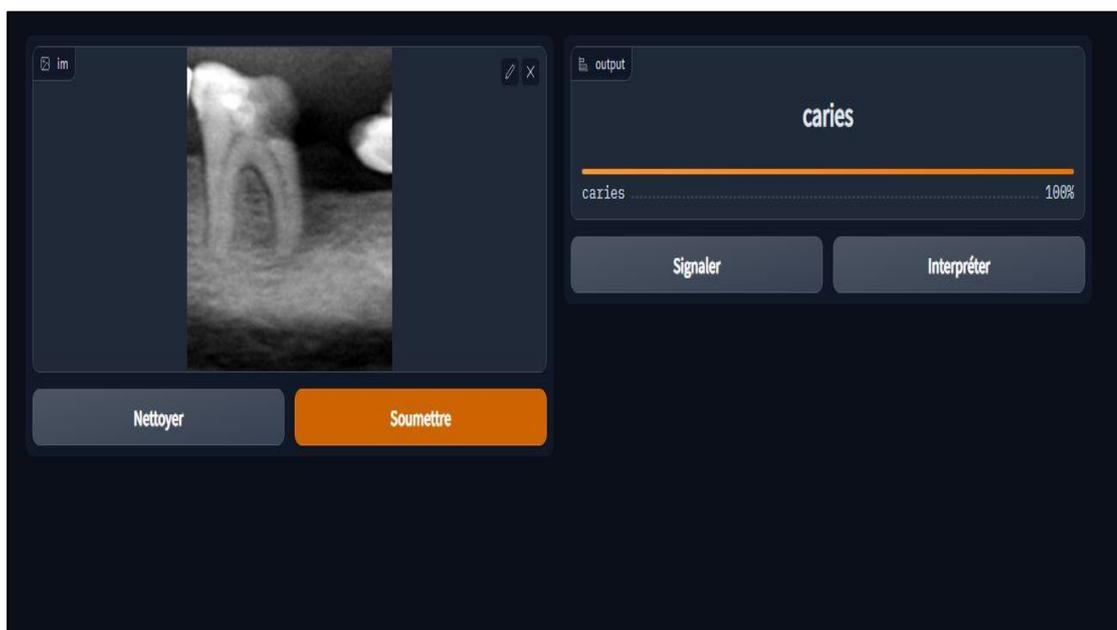


Figure 0-19 : Interface Graphique développée.

Pour utiliser cette application, il faudra tout d'abord se connecter à l'adresse web suivante : 84766.Gradio.app (adresse qui change à chaque compilation du programme)

- ✓ Une fois connecté, l'utilisateur est amené à télécharger l'image de la dent à traiter (de type X-Ray)
- ✓ On clique alors sur le bouton soumettre pour que le programme que nous avons développé prenne en charge l'image téléchargée et affiche le résultat de la classification obtenue.
- ✓ Un bouton supplémentaire nommé « Nettoyer » est à utiliser lorsqu'on veut effacer les données traitées afin de permettre l'analyse d'une nouvelle image

Remarques :

- Les résultats obtenus sont très satisfaisants même avec des images téléchargées sur Google.
- Pour que cette application soit permanente et toujours disponible sur le net, il faudra par la suite procéder au paiement de l'abonnement, sinon sa date de validation est de seulement 72 heures.

IV.6 Conclusion

Nous avons présenté dans ce chapitre une approche de classification basée sur les réseaux de neurones convolutionnels.

Pour cela, nous avons réalisé un système de classification de la carie dentaire en utilisant une base de données avec différentes architectures. Nous avons comparé ces dernières afin de choisir la plus appropriée et la plus performante pour notre objectif. La comparaison des résultats trouvés a montré que le nombre d'Epoch, la taille de la base de données et la profondeur de réseaux, sont des facteurs importants pour l'obtention de meilleurs résultats

Conclusion Générale

Dans le cadre de notre travail, nous avons abordé un des algorithmes de Deep Learning qui est le réseau de neurones convolutifs CNN en se basant sur le Transfert Learning (ou apprentissage par transfert) pour résoudre notre problématique.

Ce mémoire consiste donc à développer une application qui va nous permettre de faire une classification de la carie dentaire et de donner le pourcentage de cette dernière pour aider le dentiste d'évaluer le pronostic et de permettre une prise en charge adaptée à chaque type de de la carie dans le but d'éviter l'extraction.

Nous avons fait un aperçu sur la description anatomique de la dent et les complications de la carie dentaire, ainsi que les différents systèmes de classifications médicales. Passant par une recherche bibliographique qui expose les différentes méthodes, architectures et techniques qui ont été proposées pour la détection et la classification de la carie dentaire, on s'est intéressé surtout aux réseaux de neurones convolutifs CNN et l'apprentissage par transfert.

Nous avons mis en place un système de classification des caries, et nous avons appliqué deux architectures, l'architecture séquentielle (simple) et VGG-16, pour classer une dent saine d'une dent touchée par la carie.

Nous avons mené une étude comparative de différentes architectures afin de sélectionner le meilleur modèle pour implanter notre application web.

Nous avons obtenu une bonne précision de 97,06%.

Comme perspectives futures, nous pouvons citer :

- Développer un algorithme qui fait la segmentation automatique de chaque dent.
- Développer notre application web qui permettra de graduer la sévérité de la carie dentaire, mais avec des images panoramiques.

Bibliographie

-
- [1] : « Cavité buccale - Définition ». Journal des Femmes Santé. <https://sante-medecine.journaldesfemmes.fr/faq/38357-cavite-buccale-definition> (consulté le 1 mars 2022).
- [2] : «Anatomie de la cavité Buccale », <https://quizlet.com/408610980/anatomie-de-la-cavite-buccale-flash-cards/> - Google Search ».
- [3] : « Dent - Définition et Explications ». <https://www.techno-science.net/glossaire-definition/Dent.html> (consulté le 1 mars 2022).
- [4] : S. Rankin et M. Lennon. « MANUEL DE SANTÉ BUCCO-DENTAIRE », 2014, https://www.teethrelief.org.uk/wp-content/uploads/2019/03/FRENCH_Oral-Health-Manual_2017_ISBN_sec.pdf , (consulté le 1 mars 2022) .
- [5] : « Les maladies des gencives ou maladies parodontales - Dentiste Tremblay en France (93) ». *Espace dentaire du Vert Galant*. <https://www.centredentaireduvertgalant.com/les-maladies-parodontales-gingivite-et-parodontite> (consulté le 1 mars 2022).
- [6] : « ce583 | Facteurs dans le processus de la carie dentaire | dentalcare.ca ». <https://www.dentalcare.ca/fr-ca/formation-professionnelle/cours-de-formation-continue-en-soins-dentaires/ce583/facteurs-dans-le-processus-de-la-carie-dentaire> (consulté le 1 mars 2022).
- [7] : « Les abcès dentaires : causes et traitements - Dentiste - Centre dentaire Les Lilas (93260) ». <https://www.centredentairedeslilas.com/abces-dentaires-causes-symptomes-et-traitements> (consulté le 1 mars 2022).
- [8] : « Les caries dentaires: causes et traitements - Ma santé bucco-dentaire », 2021, <https://www.lecourrierdudentiste.com/lepatient/blog/les-caries-dentaires-causes-et-traitements.html> (consulté le 1 mars 2022).
- [9] : « Les types de radiographies dentaires - Ma santé bucco-dentaire », 2021, <https://www.lecourrierdudentiste.com/lepatient/blog/les-types-de-radiographies-dentaires.html> (consulté le 5 mars 2022).
- [10] : « Anatomie de la dent, surfaces et nomenclature | Bücco ». Bücco - Guide des soins, Trouver le bon dentiste selon vos besoins. <https://www.guidedessoins.com/dent-anatomie-surfaces-nomenclatures/> (consulté le 5 mars 2022).
- [11] :« Radiographies Dentaires | Studio Dentaire », 2017, <https://www.studiodentaire.com/traitements/fr/radiographies-dentaires.php> (consulté le 5 mars 2022).
-

- [12] : C.R. Renee, R. Vanithamani, et R. Dhivya, « Dental Caries Detection Using NIR Imaging Technique ». In *International Conference on Recent Trends in Engineering, Science & Technology - (ICRTEST 2016)*, Hyderabad, India: Institution of Engineering and Technology, 18 (4.) -18 (4.). <https://digital-library.theiet.org/content/conferences/10.1049/cp.2016.1486> (consulté le 25 février 2022).
- [13]: Albahbah, Ainas, Hazem El-Bakry, et Sameh Abdelghany, « Detection of Caries in Panoramic Dental X-ray Images using Back-Propagation Neural Network ». *International Journal of Electronics Communication and Computer Engineering* 7: 250-56, 2016.
- [14] : M. Sornam et M. Prabhakaran, « A new linear adaptive swarm intelligence approach using back propagation neural network for dental caries classification ». In *2017 IEEE International Conference on Power, Control, Signals and Instrumentation Engineering (ICPCSI)*, pp. 2698-2703.
- [15] : P. Singh et P. Sehgal, « Automated Caries Detection Based on Radon Transformation and DCT ». In *2017 8th International Conference on Computing, Communication and Networking Technologies (ICCCNT)*, Delhi: IEEE, pp.1-6. <http://ieeexplore.ieee.org/document/8204030/> (consulté le 25 février 2022).
- [16] : S.A. Prajapati, R. Nagaraj, et S. Mitra, « Classification of dental diseases using CNN and transfer learning ». In *2017 5th International Symposium on Computational and Business Intelligence (ISCBI)*, pp. 70-74.
- [17] : D. Adel et al., «Oral Epithelial Dysplasia Computer Aided Diagnostic Approach». In 2018, 13th International Conference on Computer Engineering and Systems (ICCES), , pp. 313-18.
- [18] : S.T.A. Aberin et J.C. de Goma, « Detecting Periodontal Disease Using Convolutional Neural Networks ». In *2018 IEEE 10th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment and Management (HNICEM)*, pp. 1-6.
- [19]: J-H. Lee, K. Do-Hyung, S-N. Jeong, et S-H. Choi, « Detection and Diagnosis of

- Dental Caries Using a Deep Learning-Based Convolutional Neural Network Algorithm ». *Journal of Dentistry*, 2018, 77: pp.106-11.
- [20]: J. Yang et al., « Automated Dental Image Analysis by Deep Learning on Small Dataset ». In *2018 IEEE 42nd Annual Computer Software and Applications Conference (COMPSAC)*, pp. 492-97.
- [21]: J. Krois et al., « Deep Learning for the Radiographic Detection of Periodontal Bone Loss ». *Scientific Reports*, 2019, 9(1): 8495.
- [22]: J. Kim, H-S. Lee, I-S. Song, et K-H. Jung, « DeNTNet: Deep Neural Transfer Network for the Detection of Periodontal Bone Loss Using Panoramic Dental Radiographs ». *Scientific Reports*, 2019, 9(1): 17615.
- [23]: F. Schwendicke et al, « Deep Learning for Caries Lesion Detection in Near-Infrared Light Transillumination Images: A Pilot Study ». *Journal of Dentistry*, 2020, 92: 103260.
- [24]: V. Geetha, K. S. Aprameya, et M.H. Dharam, « Dental Caries Diagnosis in Digital Radiographs Using Back-Propagation Neural Network ». *Health Information Science and Systems*, 2020, 8(1): 8.
- [25]: D. Verma, P. Sunaina, P. Srikanth et S. Komal Smriti, « Anomaly Detection in Panoramic Dental X-Rays Using a Hybrid Deep Learning and Machine Learning Approach ». In *2020 IEEE REGION 10 CONFERENCE (TENCON)*, Osaka, Japan: IEEE, 263-68. <https://ieeexplore.ieee.org/document/9293765/> (consulté le 24 février 2022).
- [26]: M. Fukuda et al., « Evaluation of an Artificial Intelligence System for Detecting Vertical Root Fracture on Panoramic Radiography ». *Oral Radiology*, 2020, 36(4): 337-43.
- [27]: D. Saini, J. Richa, et A. Thakur, « Dental Caries early detection using Convolutional Neural Network for Tele dentistry ». In *2021 7th International Conference on Advanced Computing and Communication Systems (ICACCS)*, , 958-63.
- [28]: P. Singh et S. Priti Sehgal., « G.V Black Dental Caries Classification and Preparation Technique Using Optimal CNN-LSTM Classifier ». *Multimedia Tools and Applications*, 2021, 80(4): 5255-72.
- [29]: L. Lian, Z. Tianer, Z. Fudong, et Z. Haihua Zhu, « Deep Learning for Caries

- Detection and Classification ». *Diagnostics*, 2021, 11(9): 1672.
- [30]: S. Lee et al. , « Deep Learning for Early Dental Caries Detection in Bitewing Radiographs ». *Scientific Reports*, 2021, 11(1): 16807.
- [31]: A. Procházka, C. Jindřich, V. Oldřich , et D. Mandic, « Incremental Deep Learning for Reflectivity Data Recognition in Stomatology ». *Neural Computing and Applications*, 2022. <https://doi.org/10.1007/s00521-021-06842-6> (consulté le 24 février 2022).
- [32] : A. Imak et al. , « Dental Caries Detection Using Score-Based Multi-Input Deep Convolutional Neural Network ». *IEEE Access*, 2022, 10: 18320-29.
- [33] : O. Derkaoui, « Les Algorithmes du Machines Learning», <https://www.youtube.com/watch?v=A10VZ3bPtOI> (consulté le 27 Février 2022).
- [34] : « Apprentissage Supervisé : Introduction » IN *Machine Learnia*. <https://machinelearnia.com/apprentissage-supervise-4-etapes/>, 2019, (consulté le 27 Février 2022).
- [35] : « Apprentissage Supervisé Vs. Non Supervisé » In *Analytics & Insights*. <https://analyticsinsights.io/apprentissage-supervise-vs-non-supervise/>, 2019 (consulté le 27 Février 2022).
- [36] : J.L. Cleuziat, « L'intelligence artificielle en radiologie dentaire : une revue systématique de la littérature », 2020 : 40 (27 Février 2022).
- [37] : « Quality of Dental Care with the Power of AI ». *ORCA Dental AI*. <https://www.orca-ai.com/>, 2022, (consulté le 28 Février 2022).
- [38] : « Les SVM, Support Vector Machine », *Analytics & Insights*. <https://analyticsinsights.io/les-svm-support-vector-machine/> , 2019, (consulté le 28 Février 2022).
- [39] : « les svm explication en francais – Recherche Google ». (consulté le 28 février 2022).
- [40] : M-J. Vieille, « Arbre de décision, comment ça marche? » *Lovely Analytics*, 2016. <https://www.lovelyanalytics.com/2016/08/16/decision-tree-comment-ca-marche/> (consulté le 28 Février 2022).
- [41] : N. Dérobert, « Outil - arbre de décision ». *commentdecider.com*. <https://commentdecider.com/outil-arbre-decision.html> (consulté le 28 février 2022).
- [42] : « La régression logistique,Qu'est-ce que c'est ? », *Formation Data Science |*

DataScientest.com, 2020. <https://datascientest.com/regression-logistique-quest-ce-que-cest> (28 février 2022).

[43] : W.J. Zhang, et al. , « On Definition of Deep Learning ». In 2018 World Automation Congress (WAC), Stevenson, WA: IEEE, 2018 1-5.

<https://ieeexplore.ieee.org/document/8430387/> (consulté le 28 Février 2022).

[44] : C. Couchoud, « 9 - Régression logistique ».

<https://epidemionephro.com/nephrologie/sites/default/files/pdf/9%20-%20R%C3%A9gression%20logistique.pdf>.

[45]: « 27 Incredible Examples Of AI And Machine Learning In Practice | Machine Learning Artificial Intelligence, Deep Learning, Artificial Intelligence Algorithms ».

<https://www.google.com/imgres> (consulté le 28 Février 2022).

[46] : « Qu'est ce qu'un réseau de neurones convolutif (ou CNN) ? » OpenClassrooms.

<https://openclassrooms.com/fr/courses/4470531-classez-et-segmentez-des-donnees-visuelles/5082166-quest-ce-quun-reseau-de-neurones-convolutif-ou-cnn> (consulté le 28 Février 2022).

[47] : « Découvrez les différentes couches d'un CNN ». OpenClassrooms.

<https://openclassrooms.com/fr/courses/4470531-classez-et-segmentez-des-donnees-visuelles/5083336-decouvrez-les-differentes-couches-dun-cnn> (consulté le 28 Février 2022).

[48] : Y.S. Obam, « Comprendre Les Réseaux de Neurones Convolutifs (CNN) », 2020.

<https://yannicksergeobam.medium.com/comprendre-les-r%C3%A9seaux-de-neurones-convolutifs-cnn-d5f14d963714> (consulté le 28 Février 2022).

[49] : « Apprenez à construire un CNN et gagnez du temps avec le Transfer Learning

».

OpenClassrooms. <https://openclassrooms.com/fr/courses/4470531-classez-et-segmentez-des-donnees-visuelles/5088816-apprenez-a-construire-un-cnn-et-gagnez-du-temps-avec-le-transfer-learning> (consulté le 28 Février 2022).

[50] : « *VGG16 architecture* », Computing Expertise & Legacy.

<https://iq.opengenus.org/vgg16/> (consulté le 27 Avril 2022).

[51] : « *Understanding the VGG19 Architecture* ».

<https://iq.opengenus.org/vgg19-architecture/> (consulté le 27 Avril 2022).

[52] : « *inceptionresnetv2* », HelpCenter, 2021,

<https://www.mathworks.com/help/deeplearning/ref/inceptionresnetv2.html;jsessionid=>

c8da9c aa455398c0f2b773f169a4 (consulté le 27 Avril 2022).

[53] : A. Alemi, « *Improving Inception and Image Classification in TensorFlow* », Google AI Blog, 2016, <https://ai.googleblog.com/2016/08/improving-inception-and-image.html> (27 Avril 2022).

[54] : K. Hyejin, « Intro to Deep Learning — performance metrics(Precision, Recall, F1, ROC, PR, PRG) »,2021. <https://hk3342.medium.com/intro-to-deep-learning-performance-metrics-precision-recall-f1-roc-pr-prg-87f5073f9354> (consulté le 27 Avril 2022).

[55] : (GitHub - mturkoglu23/DentalCariesDetectioNET-: Dental Caries Detection using Score-Based Multi-Input Deep Convolutional Neural Network s. d. <https://github.com/mturkoglu23/DentalCariesDetectioNET->)

[56] : « *Qu'est-ce que Colaboratory ?* ». <https://colab.research.google.com/notebooks/intro.ipynb?hl=fr>, (consulté le 23/04/2022).

[57] : « Qu'est-ce que le Python et quelle est son utilisation ? Conseils, Emploi & Tech», 2020. <https://mobiskill.fr/blog/conseils-emploi-tech/quest-ce-que-le-python-et- quelle-est-son-utilisation/> (consulté le 23/04/2022).

[58] : « *Python -Logo-Png-Image* », 2017. <https://blog.savoirfairelinux.com/fr/ca/2017/revue-de-presse-inno-7/python-logo-png-image/> (consulté le 23/04/2022).

[59] : « *Why TensorFlow* ». Disponibl <https://www.tensorflow.org/>, (consulté le 23/04/2022).

[60] : « *Keras* », <https://keras.io/> (consulté le 23/04/2022).

[61] : S. Sanya, « *Build User Interface with GRADIO for your Deep Learning Project!* »,Analytics Vidhya, 2021.

<https://www.analyticsvidhya.com/blog/2021/06/build-user-interface-with-gradio-for-your-deep-learning-project/> (consulté le 23/04/2022).

Annexes

Annexe 1 : Code source des Bibliothèques utilisées

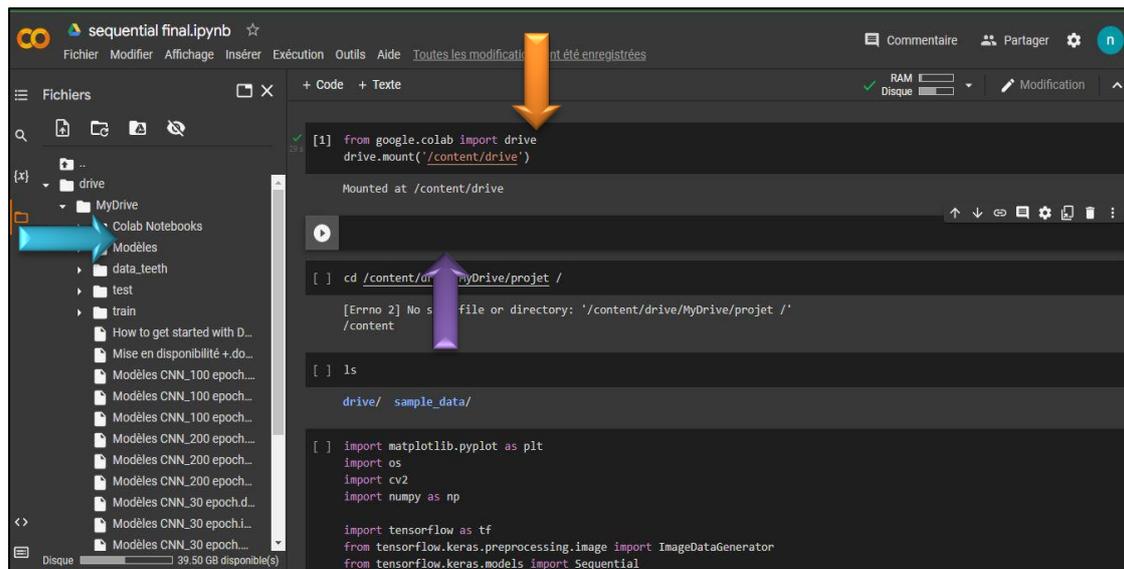
```
import matplotlib.pyplot as plt
import os
import cv2
import numpy as np

import tensorflow as tf
from tensorflow.keras.preprocessing.image import ImageDataGenerator
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense, Dropout, Activation, Flatten
from tensorflow.keras.layers import Conv2D, MaxPooling2D
from tensorflow.keras.callbacks import TensorBoard
from keras.callbacks import EarlyStopping, ModelCheckpoint
import tensorflow.keras as keras
from keras.preprocessing.image import img_to_array, load_img
```

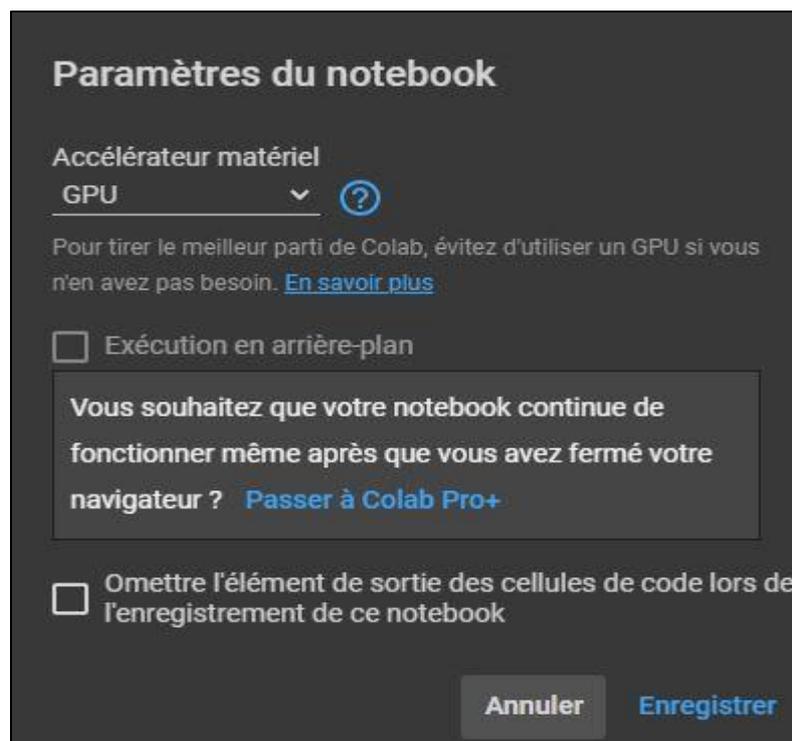
Annexe 2 : Configuration du Notebook de Google Colab

La figure suivante montre la configuration du Notebook :

- ✓ Flèche orange : L'autorisation à notebook pour accéder à nos fichiers Google Drive.
- ✓ Flèche violet : Conçu pour écrire notre code.
- ✓ Flèche bleu : Montre les fichiers du Google Drive après la connexion.



Avant de commencer l'exécution nous choisissons GPU comme Accélérateur matériel.



Annexe 4 : L'interface Finale

