

Année 2020

N° 3638

SYSTÈME INFORMATIQUE D'AIDE AU
DIAGNOSTIC MÉDICAL : APPORT DE
L'APPRENTISSAGE APPROFONDI EN
ODONTOLOGIE

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

Présentée et soutenue publiquement par

LACÔTE Titouan

Né le 24 janvier 1992

Le X juin 2020 devant le jury ci-dessous :

Président : Monsieur le Professeur Yves AMOURIQ

Assesseur : Monsieur le Professeur Pierre WEISS

Assesseur : Madame le Docteur Fabienne JORDANA

Assesseur : Monsieur le Docteur Samuel SERISIER

Directeur de thèse : Monsieur le Professeur Yves AMOURIQ

UNIVERSITE DE NANTES	
<u>Président</u> Pr LABOUX Olivier	
FACULTE DE CHIRURGIE DENTAIRE	
<u>Doyen</u> Pr GIUMELLI Bernard	
<u>Assesseurs</u> Dr RENAUDIN Stéphane Pr SOUEIDAN Assem Pr WEISS Pierre	
PROFESSEURS DES UNIVERSITES PRATICIENS HOSPITALIERS DES C.S.E.R.D.	
Mme ALLIOT-LICHT Brigitte	M. LESCLIOUS Philippe
M. AMOURIQ Yves	Mme PEREZ Fabienne
M. BADRAN Zahi	M. SOUEIDAN Assem
M. GIUMELLI Bernard	M. WEISS Pierre
M. LE GUEHENNEC Laurent	
PROFESSEURS DES UNIVERSITES	
M. BOULER Jean-Michel	
MAITRE DE CONFERENCES DES UNIVERSITES	
Mme VINATIER Claire	
PROFESSEURS EMERITES	
M. JEAN Alain	
ENSEIGNANTS ASSOCIES	
M. GUIHARD Pierre (Professeur Associé)	
Mme LOLAH Aoula (Assistant Associé)	
MAITRES DE CONFERENCES DES UNIVERSITES PRATICIENS HOSPITALIERS DES C.S.E.R.D.	ASSISTANTS HOSPITALIERS UNIVERSITAIRES DES C.S.E.R.D.
M. AMADOR DEL VALLE Gilles	M. ALLIOT Charles
Mme ARMENGOL Valérie	Mme ARRONDEAU Mathilde
Mme BLERY Pauline	Mme BARON Charlotte
M. BODIC François	M. BOUCHET Xavier
Mme CLOITRE Alexandra	Mme CLOUET Roselyne
Mme DAJEAN-TRUDAUD Sylvie	M. FREUCHET Erwan
M. DENIS Frédéric	M. GUIAS Charles
Mme ENKEL Bénédicte	Mme HASCOET Emilie
M. GAUDIN Alexis	Mme HEMMING Cécile
M. HOORNAERT Alain	M. HIBON Charles
Mme HOUCHMAND-CUNY Madline	M. HUGUET Grégoire
Mme JORDANA Fabienne	M. KERIBIN Pierre
M. KIMAKHE Said	M. OUVARD Pierre
M. LE BARS Pierre	M. RETHORE Gildas
Mme LOPEZ-CAZAUX Serena	M. SARKISSIAN Louis-Emmanuel
M. NIVET Marc-Henri	M. SERISIER Samuel
M. PRUD'HOMME Tony	
Mme RENARD Emmanuelle	
M. RENAUDIN Stéphane	
Mme ROY Elisabeth	
M. STRUILLLOU Xavier	
M. VERNER Christian	
PRATICIENS HOSPITALIERS	
Mme DUPAS Cécile (Praticien Hospitalier)	Mme QUINSAT Victoire (Praticien Hospitalier Attaché)
Mme BRAY Estelle (Praticien Hospitalier Attaché)	Mme RICHARD Catherine (Praticien Hospitalier Attaché)
Mme LEROUXEL Emmanuelle (Praticien Hospitalier Attaché)	Mme HYON Isabelle (Praticien Hospitalier Contractuel)

Par délibération en date du 6 décembre 1972, le Conseil de la Faculté de Chirurgie Dentaire a arrêté que les opinions émises dans les dissertations qui lui seront présentées doivent être considérées comme propres à leur auteurs et qu'il n'entend leur donner aucune approbation, ni improbation.

À notre président et directeur de thèse
Monsieur le Professeur Amouriq

Professeur des Universités - Praticien Hospitalier des Centres de Soins
d'Enseignement et de Recherche Dentaires
Docteur de l'Université de Nantes
Habilité à Diriger les Recherches
Département de Prothèses
Chef de Service d'Odontologie Restauratrice et Chirurgical

*Pour m'avoir fait l'honneur d'accepter la présidence et la direction de cette thèse,
Pour m'avoir aiguillé à travers la rédaction de cette thèse,
Veuillez trouver dans ce travail l'expression de toute ma reconnaissance
et de ma profonde gratitude.*

À notre assesseur
Monsieur le Professeur Weiss

Professeur des Universités - Praticien Hospitalier des Centres de Soins
d'Enseignement et de Recherche Dentaires
Docteur de l'Université de Nantes
Habilité à Diriger les Recherches
Directeur de l'équipe REGOS au sein d'RMeS (Laboratoire "Regenerative Medicine
and Skeleton") - INSERM U 1229
Vice-Doyen, chargé de la Recherche (Faculté dentaire)
Biomatériaux - Biophysique – Radiologie

*Pour m'avoir fait l'honneur de participer à ce jury de thèse,
Pour votre soutien et votre disponibilité auprès des étudiants,
veuillez trouver ici le témoignage de mon profond respect.*

À notre assesseur
Madame le Docteur Jordana

Maître de Conférences des Universités - Praticien Hospitalier des Centres de Soins
d'Enseignement et de Recherche Dentaires
Docteur de l'Université de Bordeaux
Département de Sciences Anatomiques et Physiologiques, Occlusodontiques,
Biomatériaux, Biophysique, Radiologie.

*Pour me faire l'honneur de siéger dans ce jury,
Pour vos enseignements, votre investissement et
votre disponibilité auprès des étudiants
Veuillez accepter mes remerciements les plus sincères
pour l'intérêt porté à ce travail.*

À notre assesseur
Monsieur le Docteur Serisier

Assistant Hospitalier Universitaire des Centres de Soins d'Enseignement et de
Recherche Dentaires
Département de Sciences Biologiques

*Pour m'honorer de votre présence dans ce jury,
Pour votre sympathie à mon égard ainsi que les quelques
moments et expériences partagés au cours de mes études,
Veuillez trouver ici l'expression de ma considération
et mes remerciements les plus sincères.*

Table des matières :

Introduction.....	11
I. L'apprentissage approfondi : histoire et principes de bases.....	12
1. Le neurone formel de McCulloch et Pits.....	12
1.1 Le système nerveux animal.....	12
1.2 Représentation mathématique.....	13
2. Le perceptron.....	15
2.1 L'organisation du perceptron de Rosenblatt.....	15
2.2 L'apprentissage du perceptron.....	17
2.3 Les limites du perceptron.....	19
3. Le perceptron multicouche ou réseau « feed forward ».....	19
3.1 Le concept architectural.....	19
3.2 L'entraînement des perceptrons multicouches.....	20
3.2.1 La fonction de perte.....	20
3.2.2 La descente de gradient.....	21
3.2.3 La rétropropagation.....	21
4. La révolution de l'apprentissage profond.....	23
4.1 Le réseau AlexNet lors de l'ImageNet challenge.....	23
4.2 Les différentes architectures de réseaux utilisées.....	23
4.2.1 Les réseaux pré-entraînés non supervisés.....	23
4.2.1.1 Les auto-encodeurs.....	24
4.2.1.2 Les machines de Boltzmann profondes.....	24
4.2.1.3 Les réseaux de neurones contradictoires génératifs.....	25
4.2.2 Les réseaux de neurones convolutifs.....	25
4.2.3 Les réseaux de neurones récurrents.....	28
II. Les systèmes informatiques d'aide au diagnostic médical (SAMD).....	30
1. Les caractéristiques des SAMD.....	30
1.1 Les rôles des SAMD.....	30
1.2 La composition des SAMD.....	31
1.2.1 La base de donnée.....	31
1.2.2 Le moteur d'inférence.....	31
1.2.3 Le module d'explication.....	32
1.2.4 L'interface avec l'utilisateur.....	32

2. Les applications des SAMD utilisant les réseaux de neurones.....	32
2.1 Système d'analyse d'images médicales.....	33
2.1.1 Images de structures macroscopiques.....	33
2.1.2 Images de structures microscopiques.....	33
2.1.3 Radiographie et imagerie 3D.....	34
2.1.3.1 Détection des lésions et des maladies.....	35
2.1.3.2 Classification et diagnostic.....	35
2.1.3.3 Quantification.....	36
2.1.3.4 Segmentation.....	36
2.2 Système s'appuyant sur une base de donnée électronique médicale.....	36
2.2.1 Détection de maladie.....	36
2.2.2 Catégorisation de patients.....	37
2.2.3 Elaboration de plan de traitements.....	37
2.2.4 Prévention.....	38
2.3 Dispositifs de surveillance des variables physiologiques.....	38
2.3.1 Examens complémentaires.....	38
2.3.2 Prise en charge à distance des patients.....	38
2.4 Système d'analyse du génome.....	39
2.4.1 L'expression du génome.....	39
2.4.2 La prévention des maladies génétiques.....	40
III. L'apprentissage approfondi pour les système informatiques d'aide au diagnostic en odontologie.....	41
1. Les types de systèmes utilisés en chirurgie dentaire.....	41
1.1 La radiologie et l'imagerie 3D.....	41
1.2 L'analyse d'image.....	42
1.3 Les systèmes utilisant l'enregistrement de données médicales.....	43
2. Le développement et l'utilisation des systèmes.....	46
2.1 L'architecture des réseaux.....	46
2.1.1 Les réseaux de neurones à convolution (CNN).....	46
2.1.1.1 L'architecture AlexNet.....	46
2.1.1.2 L'architecture GoogleNet.....	48
2.2 La base de données.....	52
2.2.1 Méthode d'amélioration quantitatives de la base de donnée.....	52
2.2.2 Méthode d'amélioration qualitative de la base de donnée.....	53

2.3 L'entraînement des réseaux.....	55
2.3.1 La formation.....	55
2.3.1.1 Le sur-apprentissage.....	56
2.3.1.2 Le sous-apprentissage.....	56
2.3.1.3 Les époques.....	56
2.3.1.4 Exemples de stratégies appliquées par les auteurs pour des algorithmes destinés au diagnostic en odontologie.....	56
2.3.2 L'apprentissage par transfert.....	58
2.4 Les performances des systèmes d'aide au diagnostic.....	59
2.4.1 Les performances scientifiques.....	59
2.4.1.1 Méthodologie.....	59
2.4.1.2 Résultats.....	64
2.4.1.3 Discussion.....	65
2.4.2 Les performances organisationnelles.....	66
3. Les défis et perspectives du présent et de l'avenir.....	66
3.1 La quantité des données.....	66
3.2 La qualité des données.....	67
3.3 La formation des praticiens.....	68
3.4 L'acceptation par les praticiens.....	71
3.5 L'acceptation par les patients.....	71
Conclusion.....	71
Bibliographie.....	72

Introduction :

L'apprentissage profond, « deep learning » en anglais, est un concept d'algorithmes qui bouleverse actuellement l'univers de l'apprentissage machine et plus globalement de l'intelligence artificielle. Ces algorithmes, d'ores et déjà utilisés dans un large panel d'applications, sont amenés à prendre une place de choix dans le domaine médical et notamment en terme d'aide informatique au diagnostic médical.

Pour comprendre le fonctionnement de telles applications, il conviendra de s'intéresser aux principes de base de l'apprentissage profond pour ensuite aborder les panels d'opportunités offertes au diagnostic médical de manière générale et enfin détailler l'état des avancés et des méthodes de développement de ces systèmes en odontologie.

I.L'apprentissage approfondi : histoire et principes de base

1. Le neurone formel de McCulloch et Pitts (1943) (1)

Considéré comme un des travaux à l'origine du « deep learning », le neurone formel de McCulloch et Pitts est aussi l'unité de base d'un réseau de neurone. Inspiré de la biologie animale, le neurone formel est une opération mathématique qui peut être représentée schématiquement.

1.1 Le système nerveux animal

Un neurone animal est, d'une manière simplifiée, composé d'un soma où corps cellulaire, de dendrites qui reçoivent et propagent les courants électriques post-synaptique provenant des synapses en direction du soma et d'un axone qui permet la propagation des courants électriques en direction d'autres synapses.

1: Récepteur




Schéma d'un neurone par Clément Herbert.

Un neurone est activé lorsque l'activité électrique provenant de la synapse afférente dépasse son seuil d'excitabilité. Il répond à la loi du « tout ou rien ». Une fois le seuil dépassé la réponse est la même quelque soit l'intensité de l'afférence. Il transmet une impulsion via son axone.


Dans leur travaux McCulloch et Pitts avancent que la loi du « tout ou rien » suffit pour effectuer une proposition mathématique d'un neurone. Cependant ils précisent que leur représentation s'affranchie des phénomènes de période réfractaire et que le traitement formel n'est pas affecté par les phénomènes de facilitation, d'extinction et d'apprentissage. (1)

1.2 Représentation mathématique

Le neurone formel est un modèle mathématique qui peut être représenté schématiquement. Ce schéma possède plusieurs entrées, à la manière du neurone biologique avec les dendrites. Sa sortie est unique, analogiquement au neurone biologique et son axone.

Mc Culloch et Pitts ont donc conçu une opération au cours de laquelle la somme d'un certain nombre d'entrées est pondérée par des valeurs nommées « poids » est confrontée à un seuil d'activation. (1)

Une fonction dite « d'activation » entraîne la réponse du neurone à partir de la différence entre cette somme d'entrée et le seuil d'activation du neurone. Dans ces travaux la fonction utilisée est la fonction de Heaviside. Dans le cas d'une somme pondérée supérieur au seuil, le résultat de cette fonction est 1, dans le cas inverse elle est de 0. On peut donc traduire « 1 » par une activité du neurone et « 0 » par l'absence d'activation.



Représentation graphique de la fonction de Heaviside

Exemple :

Imaginons un neurone formel N dont le seuil d'activation est w . Ce neurone reçoit un nombre d'entrée x allant de 1 à k . Ces entrées sont pondérées par des « poids » p . Le neurone possède une fonction d'activation F .

On note alors la somme des entrées comme étant :


$$x_1 p_1 + x_2 p_2 + \dots + x_k p_k = \sum_{v=1}^k x_v \cdot p_v$$

L'opération qui représente le traitement des entrées par le neurone est donc :

$$F \left(\sum_{v=1}^k x_v \cdot p_v - w \right)$$

Si $x_v \cdot p_v - w > 0$ la valeur de sortie, autrement dit la réponse du neurone, est de 1.

Si $x_v \cdot p_v - w < 0$ la valeur de sortie, autrement dit la réponse du neurone, est de 0.



Les coefficients synaptiques du neurone formel sont figés, on considère qu'un tel système ne peut apprendre.

2. Le perceptron (1957)(2)

Le perceptron est considéré comme le premier réseau de neurone évolutif, il est doté de possibilités d'apprentissage.

Le premier perceptron est un classificateur binaire développé en 1957 par Franck Rosenblatt au laboratoire aéronautique de la société Cornell. Il a été financé par l'Office de la Recherche navale des Etats-Unis et était conçu pour la reconnaissance d'image à des fins militaires. Le premier perceptron avait pour but de reconnaître les lettres de l'alphabet avec des cellules photoélectrique comme capteur.

Rosenblatt est parti d'un questionnement sur la façon avec laquelle l'information sur le monde physique était perçue, stockée puis réutilisée par système biologique pour développer un système qui représente de manière probabiliste l'organisation et stockage de l'information dans le cerveau. (2)

Le développement de ce système repose sur l'hypothèse voulant que les informations nouvelles soient stockées dans le système nerveux central par le biais de la création de nouvelles connections plutôt que par la création d'une « cartographie » au sein du SNC représentant les informations enregistrées.


Rappelons que le perceptron est un classifieur binaire et qu'il ne peut être effectif que sur des variables linéairement séparables.

2.1 L'organisation du perceptron de Rosenblatt (2)

Rosenblatt définit 4 niveaux dans l'organisation de son perceptron :

1. Le premier appelé rétine et composé de cellules sensorielles (S-points) répondant à la loi du « tout ou rien » par opposition aux systèmes dans lesquels les cellules répondent de manière proportionnelle en amplitude et en fréquence au stimulus. (2)
2. Le second correspond à l'aire de projection (AI) composée de cellules d'association (A-units). Chaque cellule d'association est connectée à un groupe de « point d'origine » qui peut avoir un effet d'excitation ou d'inhibition sur la cellule. Si la somme de ses effets sont supérieure au

- seuil des A-units, elles sont activées (toujours selon la loi du « tout ou rien »). (2)
3. Dans un troisième temps l'information est traitée par l'aire d'association (AII), elle est composée de cellules A-units identiques à celles de AI et répondant sous les mêmes conditions. Les connections entre AI et AII sont établies de manière aléatoire. (2)
 4. Pour finir le dernier niveau permet d'obtenir les réponses du système. Ces réponses sont issues une nouvelle fois de cellules de type A-unit. Chaque cellule a un large nombre de points d'origine dans l'aire d'association. Un ensemble de cellules transmettant une réponse particulière est appelé « source de la réponse ». (2)



Représentation schématique de l'organisation du perceptron (2)

Les connections entre les 1^{er}, 2^{ème} et 3^{ème} niveaux sont unidirectionnelles tandis qu'entre le 3^{ème} et le 4^{ème} niveau les transmissions se font dans les 2 sens. Cette connexion bidirectionnelle agira selon deux hypothèses, soit en excitant les A-units en relation avec la source de la réponse, soit d'inhibant les A-units qui ne sont pas en relation afin de renforcer la réponse.




Schéma de l'hypothèse selon laquelle les R-units ont un effet inhibiteur sur les A-units (2)

2.2 L'apprentissage du perceptron


Le perceptron constitue une avancée du fait de sa capacité d'apprentissage.

L'apprentissage du perceptron repose sur le principe du renforcement positif. Au cours du processus d'apprentissage le perceptron est confronté à des images destinées à l'entraînement. Le résultat obtenu par le perceptron est confronté au résultat juste. Dans le cas où le résultat obtenu est conforme, les poids affectés à l'entrée des neurones ne sont pas modifiés. Dans le cas inverse ces valeurs sont modifiées grâce à une fonction donnée. L'opération est répétée un certain nombre de fois afin que le perceptron tende vers un taux de réussite de 100%.

Exemple :

Voici une représentation schématique de l'apprentissage par le perceptron focalisé sur une cellule qui peut être comprise dans la dernière couche « d'association » :

On considère les entrées x provenant de la couche précédente allant de 1 à m auxquelles sont affecté un poids w . Une valeur communément appelée biais (noté b) est ajoutée à cette somme pondérée afin de faire varier le seuil de décision pour le modèle. Cette valeur est constante et ne varie pas en fonction de l'entrée. L'opération $\sum_{i=1}^m x_i \cdot w_i + b$ comme l'entrée du neurone. Sur le même principe que pour le neurone formel si cette somme est supérieure au seuil s alors le neurone va être activé sinon aucune réponse n'est engendrée.



Le processus d'entraînement du perceptron va consister à utiliser un ensemble de données D comprenant des données d'entrée ainsi que les résultats correspondant à chacune de ces données. Le perceptron va donc itérer sur cet ensemble de données et s'adapter en fonction de l'exactitude des résultats obtenus. Cette adaptation consiste en une modification de la valeur des poids w en réalisant le calcul suivant :

On considère :

- $y(x)$ le résultat obtenu par le perceptron
- $h(x)$ le résultat qui devrait être obtenu

- a le taux d'apprentissage

On a :

$$w_m(t+1) = w_m + a(y(x) - h(x))x_m$$

Le processus d'entraînement est répété jusqu'à un certain critère d'arrêt qui peut correspondre à un nombre de répétition ou un taux de réussite.

2.3 Les limites du perceptron

Les succès du perceptron s'avéreront relatifs. Son incapacité à résoudre des problèmes non linéaires illustrés par le problème XOR. L'échec public des réseaux affaiblit le financement des recherches et l'intérêt pour ce tel algorithme. Il faudra attendre les années 80 pour voir de nouvelles avancées à l'image du réseau de neurones Feed-forward multicouche.

3. Le perceptron multicouche ou réseau de neurone profond (1986)(3)

Pour palier aux défauts du perceptron « monocouche » notamment vis à vis des problèmes non linéaires, un nouveau concept illustré dans ce travail par les recherches de Rumelhart, Hinton et Williams voit le jour.

3.1 Le concept architectural « feed-forward »

Les auteurs avancent que le perceptron est incapable de résoudre des problèmes non linéaires du fait du nombre de couches qu'il présente. Nous avons vu précédemment que le perceptron possède une couche d'entrée (aire de projection) et une couche de sortie (aire d'association). Dans le document de Rumelhart et al il est avancé que de tels

problèmes peuvent être résolus grâce à l'ajout d'une ou plusieurs couches cachées. Les couches cachées, donc situées entre la couche d'entrée et la couche de sortie, doivent permettre au réseau de réaliser une représentation interne des entrées. Cette amélioration architecturale est principalement ce qui a permis à ces réseaux de résoudre du problème non linéaire. (3)




Schéma de l'architecture de réseau avec une couche cachée (3)

Notons que dans ces réseaux l'ensemble des connexions va dans le sens de l'entrée vers la sortie et que chacune des couches sont entièrement connectée entre elles.

Les neurones peuvent être activés ou inactivés en fonction de la somme des entrées qu'ils reçoivent. Il peut y avoir des signaux activateurs ou inhibiteurs.

3.2 L'entraînement des perceptrons multicouches

La formation de ce type de réseau diffère aussi de celui du perceptron simple. Dans un premier temps il n'existait pas de règle d'apprentissage aussi puissante que celle du perceptron. Une nouvelle méthode est développée et appelée la descente de gradient stochastique.

3.2.1 La fonction de perte

La fonction de perte est un indicateur de l'écart entre le résultat obtenu et l'objectif. Cette fonction consiste à calculer la différence entre la valeur « objectif » fournie par les

données d'entraînement et la valeur trouvée par l'algorithme. Ces valeurs étant des probabilités, elles sont toujours comprises entre 0 et 1. (4)

La formule est représentée comme suit :

$$\theta = (y - y(x))^2$$

Avec θ la fonction de perte, y la valeur que l'algorithme doit trouver et $y(x)$ la valeur qu'il a réellement trouvée.

Lorsque θ tend vers 0, l'importance de l'erreur réalisé par le système est faible et lorsqu'il tend vers 1, elle est importante.

3.2.2 Le gradient et la descente de gradient

Parmi les méthodes utilisées pour entrainer un algorithme et plus particulièrement ajuster les poids, il en est une qui est privilégiée. Cette méthode consiste à calculer la dérivée de la fonction de perte. Cette dérivée indique la pente de la fonction de perte, le but est d'atteindre la pente minimale. Sur le graphique représentant une fonction de perte, ce minimum est identifiable comme le fond du « bol ». En fonction de la valeur de cette dérivée la valeur de chaque poids est adaptée pour réduire les valeurs de ce gradient au minimum.

Le processus d'entraînement consiste donc à répéter les itérations afin de descendre le gradient au fur et à mesure et d'ajuster les paramètres du réseau.

Le nombre de répétitions d'entraînement peut être fixé d'emblé ou aller jusqu'à certain taux de réussite donné et préalablement fixé. (4)

3.2.3 La rétropropagation

L'élément fondamental dans le processus d'entraînement des réseaux de neurones semble être la rétropropagation. C'est une fonction qui permet, à partir de l'importance de l'erreur effectuée par le réseau de neurone, de définir l'urgence où non à diminuer où augmenter le signal entrant. (4)

Si un réseau obtient un résultat de 0,8, là où il aurait du obtenir 1. Son erreur sera égale à $(1 - 0,8)^2 = 0,2^2 = 0,04$. Le gradient δ est la dérivée de la fonction de perte, on obtient donc $\delta = 2 \times (1 - 0,8) = 0,4$. On a donc une urgence de 0,4 à modifier les paramètres du neurone de sortie. A partir de cette valeur, la fonction de rétropropagation a la possibilité d'agir sur les neurones précédant pour augmenter ou diminuer l'intensité du signal entrant.

Ainsi de suite, en remontant à travers le réseau de neurone de la sortie vers l'entrée, les valeurs des paramètres modifiables (les poids et les biais) seront adaptées.




Schéma illustrant la rétropropagation (3)

4. La révolution de l'apprentissage profond (2012)

4.1 Le réseau AlexNet lors de l'ImageNet challenge

A la fin des années 80, les réseaux de neurone sont à nouveau laissés de côté du fait des difficultés rencontrées dans l'entraînement des réseaux de neurones sans toutefois être abandonné.

C'est en 2012 que l'apprentissage profond revient sur le devant de la scène. Un réseau de neurone de type convolutionnel nommé AlexNet remporte le concours de reconnaissance visuelle, ImageNet challenge. Cette compétition a pour but de confronter des logiciels sur leur capacité à classer et détecter des objets ou des scènes sur des images naturelles.

Durant ce concours qui utilise une base de données d'environ 22 millions d'images classées dans 22 000 catégories. AlexNet, seul réseau d'apprentissage profond présenté durant le concours, obtient de loin les meilleurs résultats en battant le record du taux le plus faible d'erreur de l'histoire du concours.

Cet épisode marque un tournant. Depuis, les réseaux de neurones ont été très largement médiatisés et utilisés dans des domaines très variés.

4.2 Les différentes architectures de réseaux utilisées (4)

Il existe différents modèles d'organisation et de fonctionnement de réseaux de neurone. Certaines structures permettent de classer plus facilement des images, tandis que d'autres ont de meilleurs résultats pour analyser des vidéos, des textes et des sons. Nous allons, ici, décrire les architectures les plus importantes.

4.2.1 Les réseaux pré-entraînés non supervisés

Les réseaux de neurones pré-entraînés non supervisés sont des réseaux qui possèdent la particularité de pouvoir extraire des caractéristiques à partir d'une base de données brute c'est à dire sans qu'il soit fourni au réseau de cible à prédire. Le pré-entraînement permettant d'extraire les caractéristiques permettant aux réseaux de trouver les solutions aux problèmes posés. (4)

Ils sont de 3 types différents :

- Les auto-encodeurs
- Les machines de Boltzmann profonde (ou DBN Deep belief network)
- Les réseaux contradictoires/génératifs antagonistes

4.2.1.1 Les auto-encodeurs

Les auto-encodeurs sont des réseaux de neurones ayant des caractéristiques semblable à celle des perceptrons multicouches dans la mesure où le sens de propagation va toujours de l'entrée vers la sortie en passant par une couche d'entrée, une ou plusieurs couches cachées et une couche de sortie. Ils utilisent la rétropropagation pour mettre à jour leur poids mais le but de ces algorithmes n'est pas de réaliser une classification de données mais une compression et une représentation de données. Un tel réseau peut être utile pour détecter des anomalies à travers sa représentation de données qu'il a été habitué à analyser. Les auto-encodeurs sont souvent utilisés pour la phase de pré-entraînement dans d'autres réseaux de neurones profonds. (4)

4.2.1.2 Les machines de Boltzmann profonde

Les machines de Boltzmann profondes (DBN pour Deep belief networks) sont des algorithmes articulés en deux parties. La première partie est composée de machine de Boltzmann restreinte, réseaux de faible étendue permettant, de manière non supervisée, l'extraction de caractéristiques et la représentation de données, et la deuxième consiste en un réseau de neurones de type perceptron multicouche.

L'extraction des données par les RBM est qualifiée de pré-entraînement puisqu'elle est utilisée pour fixer les valeurs initiales des poids du perceptron multicouche suivant les RBM. L'entraînement s'y poursuit selon un principe de rétropropagation dite « douce » de par l'utilisation d'un taux d'apprentissage plus bas qu'à l'accoutumée.

Ces réseaux sont cependant peu utilisés. Ayant une application dans la modélisation d'image, les réseaux de neurone convolutionnels leur ont été préférés.

4.2.1.3 Les réseaux de neurones contradictoires génératifs (GAN : Generative adversarial nets) (5)

Ces réseaux ont un intérêt pour créer des images similaires à des données d'entraînement. Ce type de modèle est constitué de 2 réseaux : l'un est dit « génératif » et l'autre « discriminant ».

Le principe est que le réseau génératif produise des images, semblables à celles des données d'apprentissage. Le réseau discriminant va servir à détecter si les images produites sont semblables à celles issues des données d'entraînement. Le but est de tromper le réseau discriminant de façon à ce qu'il ne fasse pas la différence entre images de synthèse et images réelles. (6)

Par exemple on peut imaginer deux réseaux formés grâce à des photos de cabinets dentaires, le réseau génératif produira des images de synthèse de cabinet dentaire et le discriminant classifera les images comme étant semblables aux réelles ou non et permettra d'apporter des petites modifications aux images de synthèses. Les images de synthèses ayant dupés le réseau discriminant seront celles retenues par le modèle.

4.2.2 Les réseaux de neurones convolutifs (CNN)(4) 6)

La conception de réseaux de neurones convolutifs a été influencée par la découverte des champs réceptifs du cortex visuel dans les années 60, ainsi les premiers réseaux de neurones à convolutions ont vu le jour dans les années 80.

L'inspiration biologique est un aspect fondamental dans le développement des CNN puisque les neurones qui les composent effectuent un « pavage » des images en entrées pour en dégager des caractéristiques localement à la manière des neurones des champs réceptifs du cortex visuel animaux.

Ces réseaux apportent de très bons résultats notamment dans la reconnaissance d'image et sont retrouvés dans de nombreuses applications dans le domaine des systèmes informatiques d'aide au diagnostic médical.

On peut décomposer les neurones de ces réseaux en deux grandes familles :

- Les neurones de convolutions dont le rôle est de traiter une portion limitée d'une image et d'en extraire les caractéristiques. (En ce sens nous trouvons une analogie avec les cellules des champs réceptifs du cortex visuel animal). Ces données sont regroupées dans des cartes de caractéristiques. Le cumul des cartes de caractéristique d'une couche constitue une image intermédiaire qui sert d'entrée dans la couche suivante.
- Les neurones de mise en commun dit « pooling ». Ils permettent une réduction de la taille des cartes de caractéristiques et permettent au réseau de conserver une bonne puissance de calcul.

Quatre principes clés caractérisent un CNN (6) :

- Les connections locales
- Les poids partagés
- La mise en commun « pooling »
- L'utilisation de plusieurs couches

Les connections locales :

D'un point de vue architectural ces neurones sont disposés dans des couches superposées mais les neurones au sein de ces couches ne sont pas systématiquement totalement reliés entre eux. Cette notion est importante dans les CNN étant donné que cette organisation a pour but de limiter le nombre de connexions entre les neurones. La diminution du nombre de connexions permettant de limiter le nombre de paramètres à apprendre et d'augmenter la puissance de calcul du réseau. Les connexions d'un neurone se limitant à une certaine portion des neurones de la couche précédente, le nombre d'entrées est drastiquement diminué par rapport à des neurones entièrement connectés aux couches précédentes (à l'image des perceptrons multicouches). Chaque suite de couches connectées étant spécialisés dans la détection de spécificités dans une région précise de l'image. (6)




Schéma de Emilie Poisson et Christian Viard-Gaudin, « [Réseaux de neurones à convolution - Reconnaissance de l'écriture manuscrite non contrainte](http://emilie.caillault.free.fr/) » [archive], sur <http://emilie.caillault.free.fr/> [archive], 2001

Les poids partagés :

Ce principe repose sur l'invariance de translation. Notion selon laquelle, dans de nombreux cas, une statistique locale sur une image est invariante par rapport à sa localisation. Autrement dit une caractéristique, quelle que soit sa position sur l'image, sera valorisée de la même façon.

Par exemple : une dent sur une radio devra être reconnue en tant que tel quelque soit sa position. De plus dans les données telles que les images qui forment une matrice (groupe de données d'une même dimension), des groupes de valeurs locales sont fortement corrélées formant des motifs locaux faciles à détecter. Pour que le principe d'invariance de translation soit respecté les neurones formant une même carte de caractéristiques partagent une même banque de filtres (caractérisés par des valeurs telles que les « poids » et les « biais »). (6)

Le partage des paramètres a aussi l'avantage de diminuer les temps d'entraînement de ces réseaux. Les ressources à traiter pour l'apprentissage étant moins importantes, la durée de l'apprentissage est réduite. (4)

La mise en commun « pooling » :

Le but de cette opération est de réduire la taille des cartes de caractéristiques progressivement pour permettre de conserver une puissance de calcul et une mémoire suffisante. L'inconvénient étant qu'en réduisant cette taille on perd en précision et donc en nombre de données. La tendance actuelle est donc d'utiliser de petits filtres. (7)




Image représentant les sorties d'un réseau de neurone convolutionnel par Le Cun, Bengio et Hinton. (6)

Sur l'image ci-dessus, tirée des travaux de Yann Le Cun, on peut observer le travail des couches de « pooling » qui compressent l'information. A noter que le terme ReLU correspond à la fonction d'activation utilisée.

En bout de chaîne, on retrouve des couches dites « entièrement connectées » dont les neurones sont entièrement connectés à la couche précédente et qui ont pour but de calculer les scores de classe qui seront utilisés comme sortie du réseau. (4)

4.2.3 Les réseaux de neurones récurrents

Les réseaux de neurones récurrents sont construits sur le même schéma que les perceptrons multicouche ou réseau feed-forward mais en y intégrant une ou plusieurs boucles, c'est à dire des connexions orientées vers un neurone ou plus largement une couche précédente.

L'objectif de ce type d'architecture est d'intégrer une temporalité dans l'analyse des données et la formulation des réponses par l'algorithme pour donner une solution à un problème le système prend en compte la réponse précédente et la regroupe avec l'information entrante pour obtenir un résultat.




Schéma simplifié du fonctionnement d'un recurrent neuronal network (RNN) (6)

Sur ce schéma qui représente une boucle au sein d'un réseau de neurone récurrent, on remarque que l'aspect récurrent du système le transforme en fait en réseau feed-forward profond où une couche cachée à un instant t reçoit comme entrée la sortie d'une couche à $t-1$. Ces couches partagent les mêmes paramètres (poids et biais).

Ce fonctionnement peut être assimilé à une forme de mémoire à court terme.

Les réseaux de neurones récurrents sont particulièrement adaptés pour l'analyse de données séquentielle telles que la lecture, les vidéos, la parole, la musique etc ...

II. Les systèmes informatiques d'aide au diagnostic médical (SAMD)

Un système informatique d'aide au diagnostic médicale peut être défini de la façon suivante : « applications informatiques dont le but est de fournir aux cliniciens en temps et lieux utiles les informations décrivant la situation clinique d'un patient ainsi que les connaissances appropriées à cette situation, correctement filtrées et présentées afin d'améliorer la qualité des soins et la santé des patients. » (8)

Les SIAMD ont vu le jour dans les années 90 aux Etats-Unis afin de diminuer le nombre d'erreur médicales en apportant une assistance au soignant pour effectuer différentes tâches dans leur exercice. Avec les avancées technologiques dans le domaine de l'informatique, notamment, ce type de systèmes est amené à prendre une place de plus en plus importante dans l'exercice des professions médicales.

1. Caractéristique des SAMD

1.1 Les rôles des SAMD

Le but des systèmes informatiques d'aide à la décision médicale est de fournir une aide aux utilisateurs de façon à obtenir les meilleurs résultats dans le traitement de leurs patients tout en assurant leur sécurité.

Un SAMD peut apporter une assistance pour plusieurs domaines :

- Permettre la détection d'erreurs médicales potentielles
- Suggérer les risques potentiels et les différentes approches dans la gestion du patient
- Suggérer la meilleure stratégie médicale en se basant sur les meilleures connaissances acquises de la science
- Organiser les plans de traitement
- Aider à recueillir, présenter et analyser les données nécessaires au diagnostic, à l'élaboration et l'exécution d'un plan de traitement (9)

1.2 La composition des SAMD

Il existe des composants retrouvés systématiquement dans ce type de logiciel.




Schéma des composants de base d'un SAMD (10)

1.2.1 La base de donnée

Tout SAMD nécessite une base de donnée. Elle est construite et mise à jour par des concepteurs de logiciel en partenariat avec les experts dans le domaine auquel l'application est destinée. Cette base de donnée est alimentée par des ressources externes telles que d'autres bases de données, des articles scientifiques et des livres. L'élaboration de celle-ci est une tâche généralement fastidieuse mais conditionne les performances du système. (10)

1.2.2 Le moteur d'inférence

Le moteur d'inférence permet de reproduire le raisonnement d'un expert dans un domaine. Il prend en considération les informations sur le patient ainsi que celles issues de la base de donnée pour tirer des conclusions. (10)

Il existe plusieurs moyens pour que l'ordinateur effectue les raisonnements.

- **Les système algorithmique** : Ce sont des systèmes bâtis sur des classifications. Ces classifications sont représentées par des arbres de décision ou des organigrammes. Ils permettent à l'utilisateur d'y cheminer jusqu'à une réponse précise

- **Les réseaux de neurones** : Ce sont des algorithmes qui nécessitent l'utilisation de données pour les former à résoudre des problèmes. Ils sont très utilisés pour la classification d'images par exemple.
- **Les systèmes probabilistes** : Ils intègrent les taux de maladie ou de problème dans une population et la probabilité de calculer divers résultats cliniques afin de calculer l'explication la plus probable pour un cas particulier. Ce type de système utilise généralement le théorème de Bayes. Bien qu'ils reflètent la probabilité relative de diagnostic ou de traitement, ils peuvent être limités par le fait que les probabilités nécessaires ne sont pas connues ou ne puissent pas être généralisées à l'ensemble de la population.
- **Les systèmes logiques/déductifs** : Composés de branchement type « si/alors » formant des chemins de raisonnement.

1.2.3 Le module d'explication

Le module d'explication n'est pas présent pour tout les SAMD, il permet d'expliquer les réponses du moteur d'inférence. (10)

1.2.4 L'interface avec l'utilisateur

Comme pour tout logiciel, les SAMD doivent permettre à l'utilisateur « d'interagir » avec ses composants. L'utilisateur peut par exemple soumettre un problème ou donner des indications sur un patient grâce à cette interface.

2. Les applications des SAMD utilisant les réseaux de neurones

L'essor de l'apprentissage approfondi en 2012 a entraîné d'importante évolution en terme de diagnostic médical. Au point que les performances porte les auteurs à penser que les réseaux de neurone sont un outil fiable qui peut permettre d'aider à accélérer le diagnostic et l'orientation des affections traitables facilitant un traitement plus précoce qui se traduit par de meilleurs résultats cliniques.

2.1 Systèmes d'analyse d'image médicale

L'analyse de l'aspect clinique et radiologique des patients est prépondérante pour l'établissement de diagnostic par les soignants. De plus, les données telles que les photos, radiographie ou les vidéos sont quasiment systématiquement numérisées offrant de nombreuses possibilités pour le développement et l'utilisation de logiciels permettant aux praticiens d'être assistés pour la lecture de ces données.

2.1.1 Images de structures macroscopiques

La reconnaissance d'image étant un domaine dans lequel les réseaux de neurones notamment les CNN excellent, on retrouve naturellement des travaux les utilisant pour le diagnostic des lésions cancéreuses de la peau (11) ou encore le diagnostic de la rétinopathie à partir de photographies fondus de la rétine.(12) Les résultats de ces réseaux de neurones, formés sur de grands échantillons, s'avèrent satisfaisant en terme de spécificité et de sensibilité et ont même déjà prouvé leur équivalence par rapport à des experts. (11) Les conclusions d'une publication plus récente, qui a démontré une haute spécificité, sensibilité et une possibilité de généralisation élevée pour la détection des glaucomes va même jusqu'à suggérer que l'utilisation d'algorithme d'apprentissage approfondie pourrait améliorer le dépistage de façon rentable et rapide. (13) Il manque cependant à ce travail une confrontation entre ce système et les standards actuels pour effectuer cette tâche afin de dégager précisément les bénéfices qui pourraient en être tiré.

2.1.2 Images de structures microscopiques

De nombreux diagnostics reposent sur l'analyse et la caractérisation des cellules issues d'un prélèvement anatomique ainsi que de leur activité sur des images de prélèvements histopathologiques observé au microscope. Pour exemple le diagnostic et la caractérisation des cancers du sein reposent en partie sur l'évaluation de l'activité mitotique des cellules tumorales. Une forte activité permet de qualifier le cancer comme agressif. (14)

Dans les travaux de Wahab et al un réseau de neurone est formé dans le but d'évaluer l'activité mitotique sur des images microscopiques de prélèvements

histopathologiques. Les ressemblances entre les cellules en cours de mitose, celles ne l'étant pas et le déséquilibre dans la base de donnée entre le nombre de cellules des deux classes ont constitué la principale difficulté pour former un tel réseau.

Les auteurs ont tentés de contourner cette difficulté et ont jugé ses performances obtenues comme encourageantes ce qui les incite à suggérer l'utilisation des CNN pour d'autres diagnostics médicaux.(14) Dans leur étude, la base de donnée comporte une proportion de cellules en cours de mitoses qui reste faible pour autant, ce qui laisse planer un doute sur la robustesse de ce moyen d'évaluation.

D'autres travaux visent à localiser et quantifier les cellules exprimant certains bios marqueurs sur image entière d'une lame préalablement préparée avec des marqueurs immuno-histo-chimiques observables au microscope à l'aide d'un algorithme d'apprentissage profond. Les résultats se sont avérés encourageant puisque les auteurs mesurent des résultats similaires entre l'algorithme entraîné et les experts humains. De plus, ils pensent que cette approche est plus robuste et reproductible que les méthodes reposant sur l'extraction préalable de caractéristique pour former l'algorithme (type machine learning). Pour finir ils suggèrent que cette approche pourrait être facilement appliqués à différents types de tissus ou d'immunocolorant dans des applications d'étude du cancer. (15) Le diagnostic en microbiologie repose sur fait de reconnaître divers genres et espèces de bactéries. Cette opération peut être assistée par ordinateur rendant les processus de reconnaissance plus automatiques et réduit ainsi le temps nécessaire à la classification. Des réseaux de neurones ont été développés pour cette tâche avec des performances satisfaisantes.(16) La base de donnée utilisée pour de cette étude est très faible et l'entraînement du réseau ainsi que son architecture ne sont pas décrit. Il conviendra d'élargir la base de donnée ainsi que d'établir plus clairement le protocole de formation du réseau de neurones afin d'avoir des informations plus précises sur le sujet.

2.1.3 Radiographie et imagerie 3D

La majorité des recherches sur l'apprentissage approfondi a été effectué jusqu'à présent dans les domaines de l'imagerie radio thoracique et l'imagerie mammaire, même si la gamme des applications s'élargie rapidement. (17)

Les radiographies, à l'image d'autre données médicales, forment des ensembles relativement peu homogènes. Contrairement à des photos d'objets, par exemple, elles peuvent varier considérablement selon les caractéristiques physiques des clichés et les

pathologies des patients. On peut ajouter que l'imagerie 3D implique des milliers d'images. Cela augmente de manière importante le nombre de calculs effectués par l'algorithme. La complexité pour les algorithmes est augmentée. C'est pourquoi actuellement la plupart des applications en radiologie sont étroitement liées à la réalisation d'une tâche spécifique. Il est donc possible de diviser les domaines d'intérêt de la radiologie en différentes catégories : détection des lésions et des maladies, classification et diagnostic, délimitation ou segmentation et quantification. (17)

2.1.3.1 Détection des lésions et des maladies

Les études ont démontré une équivalence voire une supériorité des algorithmes d'apprentissage profond par rapport à des systèmes traditionnels pour les applications de détection et ce même si ils étaient formés sur une relativement faible quantité de données (18) L'efficacité de ces algorithmes a été démontrée pour identifier les nodules pulmonaires. (19) Les applications permettent au radiologue de pratiquer de manière plus performante en passant moins de temps à rechercher fastidieusement les petites lésions. (17) Les auteurs rapportent aussi que les algorithmes d'apprentissage profond définissent eux même des caractéristiques d'intérêt au sein des caractéristiques de l'ensemble de données et peuvent être beaucoup plus nombreuses que les ensembles de caractéristiques sélectionnés par les humains. (20)

2.1.3.2 Classification et diagnostic

Des réseaux de neurones ont été formés à des tâches spécifiques de classification et de diagnostic tel que de classer des nodules pulmonaire en distinguant le caractère bénin ou malin de la lésion (21), diagnostiquer la tuberculose à partir de radiographies du thorax (22) ou de juger ou non de la position d'une sonde endotrachéale sur une radiographie pulmonaire. (23) Pour ces deux dernières applications, les auteurs calculent une aire sous la courbe de 0,99. (22,23) Ces deux algorithmes ont été développés à l'aide d'une base de données relativement faible (1007 et 720 respectivement) dont la plus réduite d'entre elles a même été augmentée à l'aide de modifications de radio préexistantes. Ce constat pose question sur la fiabilité de ces systèmes dans l'hypothèse d'une utilisation à grande échelle.

2.1.3.3 Quantification

Les caractéristiques quantitatives des radiographies comprennent la taille et la forme des structures observables mais aussi les descripteurs de la relation entre les voxels (exemple : la cooccurrence de niveau de gris ou la longueur de course), des descripteurs d'histogramme de l'intensité de l'image, les textures extraites d'images soumises à des filtres et des caractéristiques fractale complexe. Ces caractéristiques utilisées avec succès pour prédire l'évolution de pathologies ont été analysées à l'aide de méthodes statistiques standard. Les résultats ont été prometteurs, les réseaux de neurones ont le potentiel d'identifier des motifs subtils ou complexe qui peuvent échapper aux humains et aux méthodes statistiques conventionnelles. Elles peuvent être analysées soit isolément, soit en conjonction avec des ensembles de données radiologiques et endoscopiques permettant d'identifier des motifs pas perçus auparavant. (17)

2.1.3.4 Segmentation

Pour être totalement exploitables les clichés radiographiques nécessitent dans certains cas une segmentation. Cette tâche qui nécessitait beaucoup d'interventions manuelles par le passé peut désormais être assistée par des systèmes reposant sur l'apprentissage profond. (24,25)

2.2 Systèmes s'appuyant sur une base de donnée électronique médicale

2.2.1 Détection de maladie

Un réseau de neurone peut être formé à partir d'une base de donnée de patients existant et utilisé dans le but de poser un diagnostic. Le développement d'un « médecin virtuel » formé à partir des dossiers électronique de 260 000 patients sur 8 ans capable de réaliser des diagnostics en intégrant des diagnostic différentiel et une proposition de traitement médicamenteux illustrent les possibilités en la matière. (26) Les résultats obtenus lors de cette étude incitent largement à poursuivre les recherches dans ce sens pour obtenir un système suffisamment performant et fiable. DeepCare est une application

qui permet de prédire les problèmes médicaux potentiels à partir des informations sur la santé actuelle du patient. Les résultats, qui manquent cependant de précisions concernant la spécificité et même l'efficacité, sont jugés compétitifs et prometteurs par rapport à l'état actuel des connaissances par les auteurs.

2.2.2 Catégorisation de patients

La connaissance des risques accrus d'un patient vis à vis d'une maladie peut permettre la mise en place d'une surveillance spécifique qui peut favoriser un diagnostic précoce d'une pathologie chez un sujet à risque. Un algorithme a, par exemple, été entraîné à partir de données électroniques médicales pour prédire le risque clinique du syndrome coronarien précoce. Les résultats obtenus par celui-ci montrent que l'approche proposée atteint une performance compétitive par rapport aux modèles informatiques de pointe destinés à la même application. Ces résultats qui manquent de précisions dans leur publication amène les auteurs à révéler, en plus, que certains facteurs de risque extraits de l'algorithme sont non seulement conformes aux connaissances existantes mais contiennent également des hypothèses suggestives qui pourrait être validé par des investigations plus poussées. (27)

2.2.3 Elaboration de plan de traitement

L'apprentissage profond peut jouer un rôle dans le diagnostic mais aussi pour l'élaboration des traitements puis le suivi du patient. Le travail d'une équipe de l'université de Californie à San Fransisco, suggère que l'intelligence artificielle englobant l'apprentissage profond peut permettre d'améliorer la prise en charge des patient de radio-oncologie aux différents stades des traitements. Ils contiennent toutefois leur enthousiasme tant les défis à relever pour obtenir des applications suffisamment performantes pour ces taches sont nombreux. Le manque de données de formation quantitative et qualitative ainsi que leur standardisation, entre autres, est mentionnés parmi ces obstacles. (28)

2.2.4 Prévention

La prise en charge précoce des maladies est un facteur primordial dans la réussite des traitements. C'est pourquoi de nombreux outils et programmes permettent le dépistage précoce. Miotto et al ont développé un réseau de neurones formé à partir de dossiers électroniques permettant de prédire les affections à risque chez un patient. (29)

2.3 Dispositifs de surveillance des variables physiologiques des patients

2.3.1 Examens complémentaires

En dehors de l'imagerie médicale, l'analyse par des intelligences artificielles d'autres examens nécessaires au diagnostic sont à l'étude. Les applications peuvent concerner les indices glycémiques, les ECG ou les EEG (30). Une étude visant à diagnostiquer les infarctus du myocarde à partir d'ECG est parue en 2019. Les auteurs avancent dans leurs conclusions que l'algorithme qu'ils ont formé détecte aussi efficacement que les cardiologues les infarctus sur les ECG. De plus, les auteurs ont relevés que les critères d'importance pour la prise de décision de l'algorithme sont également reconnus par les cardiologues comme indiquant un infarctus du myocarde. Cette donnée valide un peu plus la démarche de l'algorithme qui nécessiterait cependant une formation sur une base de donnée plus étoffée que celle utilisée dans ce travail pour apporter des résultats probants. (31)

2.3.2 Prise en charge à distance des patients

Des applications visant à réaliser des examens et du diagnostic à l'aide d'instruments connectés sont à l'étude. La capacité des montres connectées à réaliser des ECG a permis de former un réseau de neurones qui y analyse les ECG. Les résultats ont montré que l'algorithme peut détecter la fibrillation atriale avec une certaine perte de sensibilité et de spécificité par rapport à un ECG de référence. Ce type de suivi doit être

envisagé avec des études supplémentaires pour utilisation optimale des montres connectées à des fins diagnostics en cardiologie. (32)

La saturation des services d'urgence (33) et l'augmentation des déserts médicaux (34) portent les auteurs à penser que l'intelligence artificiel peut être utilisée pour soulager le système de santé. (35)

Outre l'approche statistique et l'apprentissage automatique, certains auteurs commencent à développer une composante interactive avec le patient en intégrant la reconnaissance vocale. Des travaux ont été effectués afin de développer une IA capable d'interagir avec un patient comme un médecin virtuel. Un tel système formé pour l'exemple au diagnostic du diabète de type II sans méthode invasive a montré des performances intéressantes. Les auteurs imaginent aussi qu'il puisse réaliser l'anamnèse de patients dans le but d'identifier les cas non urgents rapidement et de les conseiller en conséquence en leur recommandant de consulter un médecin ou un spécialiste. L'objectif étant de désaturer les services d'urgence. Cependant ce type de système a tendance à se heurter à une forme de répulsion de la part des patients, variable selon leurs activités professionnelles et même leur âge. (35) Il doit aussi être mis à l'épreuve de la confrontation avec de vrais professionnels pour être un peu plus validé d'un point de vue médical. D'autant plus que les résultats publiés à l'issue de ce travail ne comportent que peu d'informations exploitables pour permettre de calculer la spécificité et la sensibilité de cet outil pour le diagnostic.

2.4 Systèmes d'analyse du génome

Les réseaux de neurones de type convolutionnels, dont les capacités de calcul sont optimisées par les couches de convolution, ont pu être entraînés sur des séquences plus grandes améliorant ainsi la pertinence de leur détection. (36)

2.4.1 L'expression du génome

L'apprentissage approfondi a un rôle important dans le séquençage et les analyses de l'expression des gènes. (37) Pour prédire les sites de liaison des protéines de liaison à l'ARN une méthode basée sur un réseau de neurone a surpassé d'autres méthodes de pointes. (38) Basset, un ensemble de sources ouvertes permet d'appliquer des réseaux de neurones profonds pour apprendre le code d'accessibilité à la chromatine et l'annotation et l'interprétation du génome non codant. (39)

2.4.2 La prévention des maladies génétiques

La baisse rapide du coût et de la difficulté de collecte de données a mis en évidence la capacité relativement limitée des chercheurs à interpréter ce que ces données disent sur les traits, en particulier dans un contexte médical. De nouvelles technologies telle que l'apprentissage machine et en particulier l'apprentissage profond sont sur le point d'aider à surmonter certains obstacles qui limitent l'étude des variations non codantes et leur impact sur les caractéristiques humaines. (40)

Un algorithme d'apprentissage profond a été développé pour prédire les variantes génétiques sur l'épissage alternatif. Ce modèle qui a reçu en entrée des séquences d'ADN seules sans annotations de maladies ou de données de population puis a noté les effets que les variantes avaient sur l'épissage alternatif a fourni des informations précieuses sur les déterminants génétiques de l'atrophie musculaire spinale, du cancer colorectal sans polypose et des troubles du spectre autistique. (41)

III. L'apprentissage approfondi pour les systèmes de diagnostic en odontologie

L'apprentissage profond et plus particulièrement les réseaux de neurones convolutionnels sont de plus en plus utilisés pour développer des systèmes informatiques d'aide au diagnostic médical. En effet, dans le domaine de l'odontologie, entre 2016 et 2018 les publications ont été en constante augmentation. (42) La majorité de ces publications est liée à l'organe dentaire mais certains auteurs travaillent sur la plaque dentaire, la gencive ou le parodonte, l'ostéoporose, les repères anatomiques, la mandibule et l'orthodontie. (42)




Fig. 1. Number of articles from 2016 to 2018.

Diagramme illustrant l'évolution des publication sur l'apprentissage en profondeur utilisant des CNN en odontologie (42)


1. Les types de systèmes utilisés en chirurgie dentaire

1.1 La radiologie et l'imagerie en 3 dimensions

L'analyse radio graphique est un domaine primordial dans le diagnostic et la planification des plans de traitement dans la pratique de l'art dentaire. Au fil du temps les

avancés technologiques en radiologie ont peu à peu transformé le quotidien des praticiens.

Les radiographies étant désormais analysées quasiment exclusivement sur support numérique (43), il apparaît logiquement que les systèmes d'aide informatique au diagnostic médical soient, en odontologie, fortement utilisés en radiologie. Qu'il soit question d'imagerie en 2 (clichés rétro-coronaire ou orthopantomogramme) ou 3 dimensions (cône beam), l'apprentissage profond est utilisé pour le développement de systèmes informatiques d'aide à la décision médicale. Depuis 2016 la fréquence de parutions de publications scientifiques sur le sujet est en augmentation et les applications sont très vastes. Elles touchent à l'odontologie légale et l'identification des corps sur la base de comparaison de CBCT anté et post mortem(44) , l'identification d'image radiologiques intra osseuse telle que la caractérisation de lésions péri apicales avec pour objectif d'une précision permettant de différencier un kyste péri apical dentaire d'une tumeur kératocystique. (45) , la détection et le diagnostic de la carie dentaire sur des radiographies rétro coronaires (46) et l'évaluation de la morphologie radiculaire des premières molaires mandibulaires à partir de radiographies panoramiques (47). Une application permettant de diminuer l'impact d'une mauvaise position des patient ou des différences morphologiques de la mâchoire entraînant une image flou lors de la prise d'un orthopantomogramme a été développée. Le réseau a la capacité d'estimer l'erreur de positionnement de l'arcade dentaire du patient et ainsi de reconstruire l'image de façon à réduire le flou. (48)



Représentation d'un CNN entraîné pour détecter sur radiographie rétro alvéolaire si une dent est compromise où non prenant en considération l'état de son parodonte sur une radiographie rétro alvéolaire. (49)

1.2 L'analyse d'image

L'analyse d'image est un domaine où l'apprentissage profond excelle. Il y a d'ailleurs fait ses preuves pour la première fois en 2012 lors de l'ImageNet challenge (50) , événement fondateur ayant relancé l'intérêt des entreprises et de la communauté scientifique pour cette technique. Depuis cette date tous les systèmes victorieux utilisent l'apprentissage approfondi.

Nombres de diagnostics en odontologie résultent de l'observation de signes cliniques intra et exo buccaux. Que ce soit en orthodontie, dentisterie esthétique en passant par la dermatologie buccale et l'occlusodontie les applications sont potentiellement nombreuses. La prise de photographie ou plus globalement l'enregistrement d'images et leur analyse est un aspect primordial dans la pratique de ces disciplines. (51)

Le système destiné à évaluer la force occlusale par rapport à la taille des marques de papier articuler sur l'attelle occlusale chez les patients atteints de bruxisme constitue un exemple concret de l'apport de système basé sur l'analyse d'image en chirurgie dentaire. (52) De la même manière que pour le système permettant de prédire la teinte obtenue après blanchiment dentaire (53), Thantornwrong et al posent les bases des services que les SIAMD spécialisés dans ce domaine peuvent rendre. Leur système basé sur une régression multiple développé sur une trentaine d'individus, n'appartient pas à la technologie de l'apprentissage profond. Cependant, les processus de développement et les objectifs quasiment identiques à ceux d'un réseau de neurone laissent penser qu'ils seraient utiles à la mise au point de tels programmes. D'autant que les performances des réseaux de neurone dans le domaine de l'analyse d'image sont excellentes. (50)

Même si de manière similaire aux autres domaines de la médecine les applications utilisant l'apprentissage approfondi en chirurgie dentaire concernent plutôt la radiographie que les autres types d'imagerie médicale (36,42) des applications utilisant des photographies ou prises de vue à l'aide de caméras intra buccales voient le jour.

Un système a été développé pour qu'il puisse repérer la présence de marqueurs inflammatoires sur des images intra buccales afin de détecter précocement les maladies parodontales. Ce dernier a été capable de distinguer une gencive enflammée d'une gencive saine à partir de la fluorescence du bio marqueur porphyrine capté par une caméra intra-oral. (54)

Le diagnostic en orthodontie sur des photographies de face des patients a pu être automatisée grâce à un réseau de neurone. Celui-ci a été formé pour évaluer les différentes parties du visage et établir des liens ou non entre ses observations d'une zone d'intérêt du visage à une autre. (55)



Drooping the corner of left eye: Mild
Straight nose, toward left: Mild
Mouth distorted to upper left: Moderate
Distortion of Jaw to the left: Mild
Protruding the lower lip: Mild
Distortion of face outline: Moderate
...

Une image tirée des travaux de Murata et al avec les étiquettes (évaluations) données par l'algorithme de diagnostic orthodontique. (55)

L'analyse d'images microscopiques par de tels algorithmes est en cours de développement en bactériologie (16) et il y a fort à parier que de telles applications vont avoir une utilité non négligeable en dentisterie, notamment en parodontologie.

1.3 Les systèmes d'aide informatique au diagnostic médical utilisant l'enregistrement de données médicales

L'enregistrement électronique de données médicales, qui s'est quasiment généralisé dans la prise en charge des patients en odontologie, constitue une base de données importante et permet le développement de SIADM.

De multiples applications vont probablement voir le jour dans ce domaine en dentisterie, où un certain nombre de variables influencent la réussite et la pérennité des traitements.

Les essais se sont révélés probant dans diverses disciplines de l'odontologie.

Pour ce qui est de la prévention, CAMBRA (CArie Management by Risk Assesment) et PEMBRA (PEriodontal Management by Risk Assesment) dégagent des variables qui ont été répertoriées au sein des dossiers des patients. Un système, les analysant, estime le risque carieux individuel et la vulnérabilité face aux maladies parodontales et propose des thérapeutiques pour y faire face. (56) (57)

En dentisterie esthétique, des variables individuelles telles que l'âge et la couleur initiale des dents influencent le résultat des blanchiments. Thanathornwrong et al ont développé un logiciel utilisant un modèle à régression multiple permettant la prédiction des résultats d'un blanchiment dentaire. Bien que l'apprentissage profond n'ait pas été utilisé et que le développement et l'évaluation d'un modèle à régression multiple aient été effectué sur des échantillons de taille très faible (respectivement 30 et 10 sujets), les auteurs montrent qu'une méthode apparentée peut s'avérer fiable pour prédire les résultats d'un blanchiment (53).

Un réseau de neurones a été construit pour juger de la nécessité d'extraire les premières prémolaires dans les traitements orthodontiques de malocclusion chez des patients âgés de 11 à 15 ans. Formé à partir d'un échantillon de données provenant de 200 patients dont 180 ont servi à l'entraînement et sans avoir recours à une phase de pré-entraînement, le réseau s'est avéré performant dans 80% des cas. (58)

Une précision de 70% a été obtenue par un système formé à détecter la présence ou non de carie chez des patients à partir de données socio-économiques et diététiques. Les résultats significatifs encouragent largement la poursuite de tels travaux pour affiner le diagnostic en chirurgie dentaire. (59)

2. Le développement et l'utilisation des systèmes

2.1 L'architecture des réseaux

2.1.1 Les réseaux de neurones à convolutions (CNN)

Les réseaux de neurones à convolutions ont pour objectif, par le biais de leurs couches convolutives, d'apprendre des caractéristiques d'ordre supérieur à partir de données. De plus, ils sont particulièrement adaptés à la reconnaissance d'objet dans des images et plus largement au diagnostic par imagerie (4) Ils sont, de fait, naturellement utilisés pour développer des logiciels destinés à l'analyse d'imagerie médicale.

Le principe de ces réseaux repose sur les couches dites convolutionnelles qui permettent d'extraire des caractéristiques qui sont fusionnées ensuite dans des couches de « pooling ».

L'architecture des algorithmes développés dans le domaine de l'odontologie est majoritairement issues de travaux préexistants dans le domaine de la reconnaissance d'image. AlexNet et GoogleNet sont deux de ces architectures souvent retrouvées dans les publications. (42)

2.1.1.1 L'architecture AlexNet (50)

Le réseau AlexNet est retrouvé à plusieurs reprises dans la littérature concernant les algorithmes de reconnaissance d'image en odontologie. (44,47) Il trouve, tout naturellement, son utilité pour le développement de tels SIAMD étant donné qu'il a été conçu spécifiquement dans le but de reconnaître des images. (50)

Nous allons décrire succinctement son architecture afin de comprendre comment sont traitées les images dans ce réseau et plus particulièrement celles utiles pour le diagnostic en odontologie.

Le réseau utilise 2 cartes graphique (dites « GPU »), ces deux cartes graphiques permettent au réseau d'avoir une structure avec 5 premières couches convolutionnelles composées de plusieurs noyaux et se disposant sur deux

étages (1 étage correspondant à 1 carte graphique). Les noyaux de chaque couche ne sont pas systématiquement reliés entre eux. En effet, seuls les noyaux de la première et de la troisième couche sont connectés à tous les noyaux de la couche suivante. Cette disposition a pour effet de diminuer le nombre de paramètres du réseau. Les couches de convolutions sont ponctuées de fonctions de pooling qui permettent réduire la taille des carte de caractéristiques issues des convolutions, diminuant la précision mais facilitant les calculs de l'algorithme.

Le réseau se poursuit ensuite par 3 couches totalement connectées incluant la couche de sortie, dernière couche du réseau.




Schéma de l'architecture du réseau AlexNet réalisé par Krizhevski et al. (50)

Cette architecture a constitué une avancée dans la mesure où l'utilisation de deux cartes graphiques plutôt qu'une a permis d'augmenter la puissance de calcul du réseau, accélérer son entraînement et donc augmenter sa précision. (50)

Dans le domaine particulier de l'odontologie, Miki et al en 2016 utilisent le réseau à AlexNet dans leur travail. Ils en déduisent que l'utilisation de l'apprentissage profond et plus particulièrement d'un réseau à convolutions permet d'obtenir des résultats d'une bonne précision pour la classification dentaire à partir de CBCT. Ces résultats sont similaires à ceux obtenus avec une architecture nécessitant une segmentation dentaire précise. Ce réseau a permis de s'abstenir de cette étape de segmentation. (44)

Cependant, l'utilisation de régions d'intérêt, la faible taille de la base de données d'entraînement et de test, le non équilibre dans la distribution du type de dents sur les images donnés à analyser et l'augmentation de la base de données à l'aide de modification d'image déjà utilisées pour la formation de l'algorithme encourageant à nuancer ces résultats.

2.1.1.2 L'architecture GoogLeNet (60)

Développée en 2014 par une équipe de chercheurs dont certains employés par l'entreprise Google, l'architecture GoogLeNet a fait ses preuves en remportant l'ImageNet challenge en 2014. Les auteurs ont développé ce réseau en ayant pour objectif d'améliorer les ressources informatiques au sein même du réseau. Pour ce faire, ils ont augmenté la largeur et la profondeur du réseau tout en maintenant un budget de calcul constant. En effet, dans ce travail le concept visant à aller « plus profondément » se retrouve de 2 différentes façons : dans un premier temps au niveau de l'introduction d'un nouveau niveau d'organisation au sein des neurones appelé « module Inception » et dans un second temps au niveau de l'architecture globale du réseau qui comprend 22 couches.

Le module Inception

L'idée du module Inception est basée sur le postulat que les caractéristiques extraites localement sur une image peuvent être corrélées avec d'autres unités locales et former des « grappes » de caractéristiques correspondant théoriquement à une région de l'image. Ces caractéristiques, constituant les entrées de la couche suivante, seraient concentrées dans des régions de faibles dimensions ce qui se traduirait par l'utilisation de convolutions de taille 1x1. Toutefois Szegedy et al font l'hypothèse qu'il puisse exister un nombre réduit de « grappes » plus dispersées dans l'espace et potentiellement couvertes par des convolutions sur des parcelles plus grandes (3x3 et 5x5 dans le cas du réseau GoogLeNet).

Les auteurs proposent donc, dans les modules Inception, de faire « convoluer » les unités des couches précédentes au sein de la couche suivante dans des convolutions de dimension 1x1, 3x3 et 5x5 en parallèle pour ensuite les faire « concaténer ».




Schéma tiré du travail de Sgezedy et al (60)

La disposition en parallèle des couches de convolutions au sein de ce module augmente la profondeur du réseau, augmentant les niveaux d'abstraction et affinant la représentation interne au sein de l'algorithme.

L'architecture globale :

Le réseau GoogleNet est constitué d'un nombre relativement important de couches successives parmi lesquelles on retrouve 9 modules inception les uns après les autres. Le réseau possède 3 sorties dont 2 interviennent avant la dernière couche de convolution. Elles ont pour but de limiter la disparition du gradient lors des phases d'entraînement du réseau.

Dans leur tentative d'utilisation d'un réseau de neurones à convolution pour détecter et diagnostiquer les lésions carieuses Lee et al en 2018 (46) utilisent l'architecture Google net Inception v3. Nous situons cette étude à un niveau de preuve B. Elle comporte quelques biais dans la construction de la base de données (radios recadrées pour qu'une seul dent apparaisse, exclusion des dents couronnées ou comportant des onlay volumineux ainsi que l'utilisation uniquement de dents permanentes) et les résultats ne sont pas confrontés à ceux obtenus par les experts humain. Cependant les résultats

obtenus sont très encourageants pour la poursuite des recherches dans ce sens en odontologie.

Cette architecture offre des performances supérieures en détection, classification et segmentation d'images et a été largement utilisée dans le domaine médical pour le classement et le diagnostic de sources d'images et de vidéos, y compris IRM, Tomodensitométrie, microscopie, ultrasons, rayons X, mammographie et fondus couleur. Les auteurs de l'étude affirment atteindre une précision et une efficacité considérables en matière de détection et de diagnostic des caries dentaires.

Les CNN se sont révélés d'autant plus adaptés à ces tâches dans la mesure où contrairement aux architectures simples et traditionnelles, les algorithmes CNN profonds effectuent la détection de bord de manière très efficace avec des représentations de caractéristiques hiérarchiques grâce à de multiples couches convolutionnelles et cachées. Par conséquent, un détecteur de carie dentaire basé sur CNN peut apprendre efficacement les modifications de localisation et morphologiques des lésions carieuses dentaires et les détecter de manière pratique et fiable. (61)



Représentation schématique de l'architecture globale du réseau GoogleNet (60)

2.2 La base de données

L'importance de la qualité et de la quantité des données est prépondérante dans le développement d'un réseau de neurone. Pour palier aux manques quantitatifs et optimiser la qualité les développeurs mis au point des techniques.

2.2.1 Méthodes d'amélioration quantitative de la base de donnée

La manipulation d'image :

- La rotation d'image : Elle consiste à effectuer une rotation des éléments destinés à la formation du réseau. Grace à cette manipulation, on considère qu'on obtient de nouvelles images qui pourront augmenter la base de donnée destinée à l'entraînement du réseau.

Plusieurs études utilisent cette technique pour augmenter leur base de donnée. Miki et al, dans le développement d'un CNN pour apparier des images tomographiques de dents *ante* et *post mortem*, l'utilisent pour augmenter le nombre de rectangles de régions d'intérêt (ROI) préalablement sélectionnés sur les cônes-beam.

Les auteurs effectuent dans cette étude, une rotation allant de -10 à +10 degrés par incréments de 5 degrés dans le plan x-y. Par le biais de ces pivotements des ROI, les auteurs estiment obtenir un échantillon égal à 5 fois l'échantillon d'origine. Après comparaison des résultats obtenus dans les différents échantillons (sans manipulation, avec utilisation de la rotation seule, avec utilisation de la transformation d'intensité seule ou avec ces 2 manipulations) ils mentionnent qu'avec l'utilisation de la rotation la précision a été augmentée. (44)

L'utilisation de ROI pour former un réseau de neurones peut entraîner une faiblesse dans ses performances. Lorsque les ROI sont utilisés, le réseau est formé sur une petite partie de l'image tandis que de tels réseaux sont destinés à analyser des images entières. Il est donc probable qu'il soit bien moins performant qu'il n'y paraît lors de sa formation.

- La transformation d'intensité : Consiste à modifier l'intensité lumineuse des images dans le but d'en obtenir de nouvelles dont les caractéristiques lumineuses sont différentes pour augmenter la quantité de donnée.

Miki et al en 2016 utilisent cette technique en complément de la rotation d'image. La transformation est mathématiquement définie comme suit :

$$y = I_{max} \cdot \left(\frac{x}{I_{max}}\right)^{1/\gamma},$$

où x et y sont les valeurs de pixel d'entrée et de sortie, respectivement, et I_{max} est la valeur de pixel maximale, qui est égale à 255 pour l'image d'entrée. Les valeurs γ de 0,75 et 1,5 ont été appliquées, ce qui a multiplié par trois le nombre d'échantillons. (44)

Même si dans cette étude les auteurs font état d'une amélioration de 5% de la précision diagnostic de leur algorithme à l'aide de l'augmentation de la base de données par les méthodes citées précédemment, la fiabilité de cette méthode reste discutable. Le système n'a pas été confronté, en test, à un nombre important de données. Un manque de diversité des données de test en découle. Il est donc difficile de conclure, avec cette étude, que ces méthodes d'augmentation des données soient suffisamment robustes pour former des systèmes destinés au diagnostic médical.

2.2.2 Méthodes d'amélioration qualitative de la base de donnée

La normalisation des données :

Il apparaît nécessaire pour former un algorithme que les qualités des données soient normalisées. Par exemple dans le cas des cone-beam, l'utilisation d'une unique valeur de Housefield pour tous les clichés (42)

La validation croisée :

Les performances d'un algorithme destiné au diagnostic médical dépendent directement de la qualité des données et de l'absence de biais. Le principe de séparer l'ensemble de la base de données en différents échantillon, avec lesquels on entraîne et teste de manière indépendante le réseau de neurone, permet de limiter les biais. (47)

L'équilibrage des données :

Les données médicale et notamment les images comportent la particularité d'être déséquilibrées. Etant donnée que les phénomènes pathologiques sont globalement plus rares à observer qu'un état sain, les bases de données en sont fortement impactées.

Pour palier à ce problème et équilibrer les données on retrouve 3 grands axes dans la littérature (14) :

- Les méthodes basées sur les datas : Ces modèles comprennent le sur-échantillonnage et le sous-échantillonnage.

Pour le sur-échantillonnage les exemples de la classe minoritaire sont augmentés en effectuant des copies exactes ou modifiées des originaux. Il existe des système capables de générer des exemples artificiels basés sur les originaux à la manière des GAN. Cependant la nature sensible des images médicales est un facteur limitant à l'utilisation de cette technique.

(14) Une autre option pour le sur-échantillonnage est d'effectuer des modifications telles que des rotations sur les classes minoritaires.

Pour le sous-échantillonnage, on supprime simplement des exemples de la classe majoritaire. Un sous échantillonnage aléatoire appliqué à cette méthode entraîne un risque de perdre de manière des informations importantes. D'autres moyens peuvent être utilisés tels qu'un sous échantillonnage basé sur le regroupement qui a montré une supériorité par rapport au sous échantillonnage aléatoire. Le sous échantillonnage basé

sur le regroupement permet de sélectionner les classes à éliminer et limiter ainsi la perte d'information. (14)

- Les méthodes basées sur les modèles : Le principe de ces méthodes n'affecte pas la distribution des données mais affecte les algorithmes de telle sorte qu'ils se concentrent davantage sur les exemples minoritaires par exemple en associant des coûts différents aux classes modifiant ainsi le mécanisme de mise à jour des poids (système AdaBoost) ou en modifiant les taux d'apprentissage pour prendre en compte le déséquilibre des classes.
- Les méthodes hybrides : Cette technique repose sur un échantillonnage intégré à un réglage effectué à partir du modèle afin de réduire les effets du déséquilibre de la distribution des données sur les performances du classifieur.

2.3 L'entraînement des réseaux

L'entraînement des réseaux est une phase primordiale de son développement. Elle va définir la capacité du réseau à atteindre les objectifs fixés par ses concepteurs.

2.3.1 La formation

Les algorithmes d'apprentissage profond ont la capacité de pouvoir apprendre eux-mêmes une tâche telle que la reconnaissance d'une structure dentaire, par exemple. Pour ce faire, on applique le principe de rétropropagation. C'est à dire qu'un jeu de données dites « de formation » est envoyé à analyser à l'algorithme qui intègre ces données via la couche d'entrée.

Celles-ci sont ensuite traitées à travers les différentes couches dites « cachées » pour qu'au final le réseau de neurones révèle en sortie les étiquettes assignées à ces données. A ce moment les résultats obtenus par le réseau sont comparés avec ceux que les formateurs désiraient obtenir.

A partir de là, si les étiquettes en sorties concordent avec les objectifs aucun paramètre n'est modifié. Dans le cas inverse, si les étiquettes ne concordent pas avec les

résultats l'algorithme a mis à jour les valeurs des poids et des biais qui sont appliqués à chaque neurone. Ce de manière rétrospective en partant de la couche de sortie pour remonter, via les couches cachées à la couche d'entrée. (4)

Cette opération est effectuée un certain nombre de fois. Le résultat obtenu peut être de 3 types : soit il est conforme aux attentes, soit on parle de sur-apprentissage ou de sous-apprentissage.

2.3.1.1 Le sur-apprentissage

Le modèle reconnaît extrêmement bien les données d'entraînement mais il y arrive moins bien pour celles de validation. Il manque donc de capacité à généraliser son apprentissage.

2.3.1.2 Le sous-apprentissage

Le modèle n'arrive pas à reconnaître les données de formations et il n'arrive pas non plus à reconnaître celle de validations.

2.3.1.3 Les époques


Une époque correspond au passage complet du jeu de données. L'entraînement est souvent réalisé sur de multiples époques. La formation du réseau résulte, ensuite, de la convergence de ces entraînements. L'augmentation du nombre d'époque dans la formation d'un réseau de neurones améliore ses performances. (17)

2.3.1.4 Exemples de stratégies appliquées par les auteurs pour des algorithmes destinés au diagnostic en odontologie

La validation croisée :

La validation croisée consiste à séparer la base de donnée de formation en plusieurs échantillons, un échantillon étant utilisé pour effectuer la validation ou le test et les autres sont utilisés comme données d'entraînement pour le réseau.

Afin de développer un réseau capable de prédire la présence ou non de second canal distal sur les premières molaire mandibulaires, Hiraiwa et al (47) utilisent cette méthode. Ils séparent leur jeu de données comportant des radio de type panoramique en 5 échantillons. Au sein de chacun de cet échantillon, un groupe est conservé pour effectuer le test de l'algorithme et les quatre autres afin de le former. La performance en terme de diagnostic pour chacun des 5 groupes d'évaluation a été obtenue à partir de ces performances une moyenne a été déterminée. Pour entrainer cet algorithme les auteurs ont décidé d'effectuer 200 époques.



Représentation schématique de l'échantillonnage de Hiraiwa et al (47)

Les résultats satisfaisants des algorithmes en matière de précision, spécificité, sensibilité, valeur prédictive positive et négative ainsi que ses performances significativement supérieures à 2 radiologues en terme de précision suggèrent que la validation croisée est une technique performante dans l'entraînement de réseaux pour l'analyse de radiographies. Elle a permis, selon les auteurs, de limiter les biais dans la base de données utilisée pour la formation. (47)

Des biais persistent dans l'élaboration de la base de donnée. Les dents sans traitements endodontiques n'ont pas été retenues, la taille de la base de données est relativement faible et les auteurs ont sélectionné des régions d'intérêt sur les radiographies panoramiques. De plus les algorithmes testés ont été confrontés à 2 spécialistes simplement. Ce qui amène à la prudence dans l'interprétation des résultats.


2.3.2 L'apprentissage par transfert

L'apprentissage par transfert dans le cas par exemple d'un CNN pour la reconnaissance d'image dans un but diagnostic consiste à utiliser un réseau de neurones déjà entraîné pour la reconnaissance d'image d'autres types de classe d'image, d'utiliser ses réglages pour les couches de convolution et de les associer à des couches entièrement connectées qui n'ont pas été formées. Les réglages de ces convolutions qui leur permettent d'effectuer des cartes de caractéristiques pour certaines classes d'images peuvent être transposés à d'autres classe d'images.

Cette méthode permet de diminuer le temps d'entraînement et d'utiliser des bases de données moins larges.

Les résultats obtenus sont satisfaisants pour le diagnostic à partir d'OCT de la rétine et sur des radiographie de poumons en pédiatrie pour diagnostiquer les pneumonies. Cette technique peut être utilisée pour le développement d'algorithmes à visée diagnostic dans les différents domaines médicaux. (62)

Cette méthode utilisée aussi pour diagnostiquer les caries sur des radiographies intra orale a permis de développer un algorithme capable d'obtenir un pourcentage de précision compris entre 82 et 89% selon le type de dents. (46) Ces résultats semblent prometteurs mais l'absence de comparaison avec d'autres méthodes de diagnostic ne permettent pas de conclure à une véritable robustesse de la technique.



Ci-dessus : représentation schématique de la méthode d'apprentissage par transfert pour un réseau destiné à diagnostiquer les rétinopathies sur des images de tomographie cohérence optique par Kermany et al (62). Les couches de convolutions sont tirées d'un réseau entraîné sur la base de données ImageNet et sont associées à des couches entièrement connectées qui sont entraînées pour le diagnostic sur des OCT de la rétine.

2.4 Les performances des systèmes d'aide au diagnostic médical

On peut juger les performances des réseaux de neurones en temps qu'un algorithme capable de fournir la bonne réponse scientifique à un problème diagnostique mais on doit aussi attendre d'un SIAMD d'être un outil permettant d'améliorer l'environnement et la charge de travail du praticien lors de son exercice. Dans cette partie nous dissocierons les performances scientifiques des réseaux de neurones des performances organisationnelles des SIAMD. Il n'existe pas d'étude à notre connaissance sur l'utilisation de SIAMD possédant comme moteur d'inférence un réseau de neurone en chirurgie dentaire. Et certaines de ces observations pourraient être différentes pour une telle application.

2.4.1 Les performances scientifiques

Pour dégager une tendance dans les performances des systèmes informatiques d'aide au diagnostic médical reposant sur l'apprentissage approfondi en odontologie, il est nécessaire d'observer de manière critique les études parues sur le sujet et utilisées dans cette thèse.

2.4.1.1 Méthodologie

Les articles utilisés pour la rédaction de cette analyse ont été sélectionnés grâce au moteur de recherche de données bibliographiques Pubmed.

Les mots clés utilisés sont :

- Deep learning
- Dental practice
- Clinical decision support system
- Artificial intelligence
- Neuronal network

D'autres articles référencés sur le moteur de recherche IEEE xlore sont tirés d'une revue systémique parue en 2019. (42)

Les articles retenus sont ceux concernant des systèmes informatiques d'aide au diagnostic médical développés à partir d'algorithmes d'apprentissage approfondi utilisables dans le domaine médical d'une part puis plus particulièrement sur le sujet de l'art dentaire.

Les critères utilisés pour l'analyse des revues de synthèse parues sur le sujet sont ceux tirés du guide d'analyse de la littérature et gradation des recommandations. Ce guide a été élaboré par l'Agence d'Accréditation et d'Evaluation de la Santé (ANAES) en janvier 2000. (63)

La HAS a lancé le 20 novembre 2019 une concertation dans le but de réaliser une grille d'évaluation des dispositifs médicaux utilisant l'intelligence artificielle. La fin de cette concertation a eu lieu le 15 janvier 2020. (64) Les résultats ne sont pas parus à ce jour. Nous avons donc réalisé un tableau mêlant la grille d'évaluation des articles diagnostique issu du guide élaboré par l'Agence d'Accréditation et d'Evaluation de la Santé (ANAES) en janvier 2000 (63), des critères issus de la notice relative au projet de grille d'analyse des dispositifs médicaux embarquant des systèmes décisionnels s'appuyant sur des procédés d'apprentissage automatique émanant de la HAS ainsi que les critères de utilisé par Hwang et al pour commenter la validité des études analysées dans leur revue de synthèse (42) que nous considérons d'un niveau de preuves correcte bien que les modalités de lecture des auteurs manquent parfois de clarté et que les résultats ne soient que partiellement mis en valeur ainsi que la. (64)

Les articles descriptifs et techniques ne sont pas intégrés à cette analyse.

	Totalement	Partiellement	Pas du tout
Les objectifs de la revue De synthèse sont clairement exposés	(42)(17)(24)		
Méthodologie			
<i>Procédure de sélection</i>			
L'auteur décrit ses sources de données	(42)(24)	(17)	
Les critères de sélection de l'étude sont pertinents	(42)(24)	(17)	
Les critères d'inclusion et de sélection des articles sont décrits	(42)(24)		(17)
Les études non publiées sont prises en compte			(42) (17)(24)
<i>Méthode d'analyse</i>			
Les modalités de la lecture sont précisées	(24)	(42)	(17)
L'auteur présente la méthode utilisée pour réaliser la synthèse des résultats	(42)(24)		(17)
<i>Résultats</i>			
L'auteur décrit les résultats	(24)	(42)(17)	
l'auteur commente la validité des études choisies	(42) (24)		(17)
Ses conclusions s'appuient sur des données fiables dont les sources sont citées	(42)(17)(24)		
<i>Applicabilité clinique</i>			
La revue de synthèse permet de répondre à la question posée	(42)(24)	(17)	


	OUI	NON	?
Objectifs			
Les objectifs sont clairement définis	(44) (48)(45)(46)(47)(49)(54)(55) (58)(59)		
Méthodologie			
<i>Développement de l'algorithme</i>			
Description de l'architecture	(44)(47)(46)(49)(54)(55) (48)(58)	(45)	
La méthode de sélection des données est décrite	(44)(45)(46)(47)(49)(54) (55)	(48)(58)	
Les systèmes sont utilisés sans présélection de « zone d'intérêt » où des méthode d'augmentation de la base données	(54)(58)	(44)(45)(46)(47) (49) (55)(48)	
La taille de la base de donnée est supérieure à 1000 unités	(49)(48)	(44)(45)(46)(47)(54)(55) (58)8)	
<i>Evaluation des capacités diagnostic de l'algorithme</i>			
Test comparé à un test de référence fiable et validé déterminé à priori	(47)(49)(54)	(44)(45)(46)(55)(48)(58)	
Fréquence de la maladie dans l'échantillon étudié correspond- elle aux données épidémiologique	(47)	(44)(49)(58)	(45)(46)(54)(55) (48)
Définition du terme "normal"	(45)(46)(47)(49)	(44)(54)(55)(48)(58)	
Résultats			
Les caractéristiques diagnostique du test sont calculées ou calculable	(44)(46)(47)(49)(54)	(45)(55)(48)(58)	
L'utilité clinique du test est recherchée	(44)(45)(46)(47)(49)(55) (54)(48)(58)		

	OUI	NON	?
Objectifs			
Les objectifs sont clairement définis	(11)(12)(14)(13) (15)(16)(18)(19) (21)(22)(23)(26) (27)(29)(30)		
Méthodologie			
<i>Développement de l'algorithme</i>			
Description de l'architecture	(11)(14)(13)(21) (22)(23)(26)(27) (29)(30)	(12)(15)(16)(18)(19)	
La méthode de sélection des données est décrite	(11)(12)(14)(13) (15)(18)(21)(22) (23)(26)(27)(29)	(16)(19)(30)	
Les systèmes sont utilisés sans présélection de « zone d'intérêt » où des méthode d'augmentation de la base données	(11)(12)(14)(13) (16)(18)(21) (27)(22)(26) (29)(30)	(15)(19)(23)	
La taille de la base de donnée est supérieure à 1000 unités	(11)(12)(14)(13) (15)(18)(19)(21) (22)(26)(27) (29)	(16)(23)(30)	
<i>Evaluation des capacités diagnostic de l'algorithme</i>			
Test comparé à un test de référence fiable et validé déterminé à priori	(11)(15)(19)(21) (22)(26)(29)	(12)(14)(13)(16) (18)(23)(27)(30)	
Fréquence de la maladie dans l'échantillon étudié correspond- elle aux données épidémiologique	(12)(14)(13)(29)	(16)(18)(22)(23)(27)	(11)(15)(19)(21)(26)
Définition du terme "normal"	(11)(12)(14)(13) (15)(23)(26)(30)	(18)(19)(21)(22)(27)	(16)(29)
Résultats			
Les caractéristiques diagnostique du test sont calculées ou calculable	(11)(12)(14)(13) (15)(18) (22)(19)(21)	(23)(26)(27)(29)(30)	(16)
L'utilité clinique du test est recherchée	(11)(12)(14)(13) (15)(16)(18)(19) (21)(22)(23)(26) (27)(29)(30)		


2.4.1.2 Résultats

L'analyse de la bibliographie de cette thèse montre que 10% des articles retenus sont des revues de synthèse et 90% sont des études.

On observe 13% de niveau de preuve A, 27% de niveau de preuve B et 60% de niveau de preuve C dans l'ensemble.



Si on se concentre sur le domaine particulier de l'odontologie, le nombre de références de grade A est de 9%, de grade B 27% et de grade C 64%.



Le degré de preuve des études nous montre que les connaissances sur les algorithmes d'apprentissage approfondi dans le domaine médical ne sont pas encore très étendues et que les systèmes ne sont, dans l'ensemble, pas suffisamment développés et testés pour être prêts à être utilisés dans la pratique quotidienne de la médecine.

2.4.1.3 Discussion

La fiabilité des algorithmes nécessite encore des améliorations. Même si ils obtiennent aujourd'hui des précisions qui ne sont pas inférieures aux spécialistes dans les domaines pour lesquels ils ont été formés, une précision plus importante que les auteurs évaluent à 98%-99% doit être obtenue pour une potentielle industrialisation des systèmes. (65)

Les systèmes évalués entre les années 2016 et 2018 par hwang et al, dépassant rarement les 90% de précisions, des progrès doivent encore avoir lieu avant la commercialisation de ces applications. Les quantités de données d'entraînement encore trop faibles ainsi que l'utilisation de régions d'intérêt présélectionnées pour l'entraînement des réseaux, ne leur permettant pas d'être formés sur des images entières font partie des éléments qui doivent être améliorés pour augmenter la précision. (42)

La Food and Drug administration ayant déjà approuvé l'apprentissage en profondeur pour des tâches complexes comme la segmentation du cœur, la détection des rétinopathies ou le suivi des tumeurs(66), les chances que des algorithmes puissent être utilisés dans la pratique des soins dentaires sont réelles.

Globalement la précision diagnostic des algorithmes d'apprentissage approfondi dans le domaine médicale se rapproche des niveaux d'expertise humaine et installe de plus en plus l'ordinateur comme un outil collaboratif (42)

2.4.2 Les performances organisationnelles

Au delà de la simple capacité d'un réseau de neurones à établir un diagnostic juste, son apport pour le clinicien qui l'utilise en tant qu'outil dans son environnement de travail se doit d'être évalué.

En effet si il augmente les difficultés en compliquant l'organisation du cabinet ou en augmentant la charge de travail, l'utilité d'un tel système doit être discutée en fonction de son apport scientifique.

En sens, Mertz et al (56) (57) posent les prémices d'une réponse dans la première enquête sur la mise en place d'un SIAMD dans l'environnement de travail de cliniciens en odontologie. Ils mesurent entre les résultats du premier et du deuxième questionnaire l'amélioration du ressenti par l'amélioration de paramètres tels que le stress, la charge de travail et l'expérience du travail sans pouvoir affirmer que l'introduction du SIAMD en est responsable. Toutefois, l'introduction n'a pas eu d'impact négatif sur ces variables. Ils suggèrent que dans leur enquête, leur outil a été bien reçu et qu'il a peut-être contribué à améliorer les conditions de travail des cliniciens.

Il n'y a pas encore eu de réelle expérience dans la durée sur l'interaction que pourrait avoir les soignants avec des intelligences artificielles aussi puissantes que celles obtenues avec l'apprentissage profond. Cependant l'idée selon laquelle les praticiens seraient remplacés par les IA est pour l'instant écartée par les spécialistes qui considèrent ce type d'outils comme un « luxe » supplémentaire permettant d'avoir un second avis en quelques nanosecondes. (67)

3. Les défis et perspectives du présent et de l'avenir

3.1 La quantité de données

La quantité des données disponibles pour le développement des réseaux de neurones s'avère être, en odontologie, un facteur limitant le perfectionnement des systèmes. Dans un certain nombre d'études la faible taille de la base de donnée pour entrainer le réseau est déplorée. (42) Même si l'utilisation de la formation contradictoire

basée sur la réalisation de légères modifications telles que des rotations sur les éléments utilisés pour la formation du réseau est utilisée dans plusieurs travaux. (44) (46) Ces difficultés persistent, dans la plupart des cas, même après augmentation du jeu de données. (47) De plus la qualité des bases de données issues de la modification d'une précédente, ne peut pas s'y égaler celle d'une base de données « originale ».

Parmi les solutions envisagées on trouve la mise en place de plateformes informatiques sécurisées permettant aux scientifiques de mettre en commun des données. Elles représentent une solution efficace pour augmenter les bases de données. (55)

Mais les réseaux de neurones dans le cas des radiologies se heurtent aussi à des difficultés par rapport à la qualité et la variabilité des paramètres des clichés. (68,69)

Toutefois le volume médian des bases de données a doublé entre 2016 et 2018 ce qui porte à croire que les solutions misent en place commence à porter leurs fruits. (42)




Diagramme représentant la taille médiane des bases de données d'entraînement entre 2016 et 2018 (42)

3.2 La qualité des données

Plusieurs études insistent sur une qualité de données insuffisante pour que le système mis au point soit suffisamment efficace. (46) En effet les performances de l'apprentissage profond étant directement dépendant de sa phase d'entraînement, les données utilisées ne doivent pas laisser de doute en terme de diagnostic. Les développeurs doivent préalablement mettre d'accord un groupe d'expert sur ces données.

La récolte des données pour former un réseau doit englober un très large choix. Pour des images intra oral par exemple, la faible diversité des angles de vue est un facteur

limitant pour l'obtention de réseaux suffisamment robustes pour avoir une réelle application clinique. (54)

La sélection manuelle de régions d'intérêt pour la formation des réseaux est source d'erreur et limite l'analyse et la comparaison des résultats obtenus. (42)

De plus le cone-beam, qui est le type d'imagerie 3D la plus populaire en chirurgie dentaire, n'utilise pas de valeurs de Housfield unitaires comme la tomodensitométrie médicale et la valeur des pixels des images acquises changent à chaque exposition. (69) Tandis que la qualité et le grossissement des radiographies panoramique dentaires dépendent du positionnement du patient. (68)

Les difficultés d'obtention de données de meilleure qualité limite la quantité de données disponible pour entraîner les réseaux limitant par conséquent la précision du réseau de neurone. Dans le cas du cone-beam, il serait avantageux qu'une norme internationale soit établie à l'avenir pour augmenter les bases de données disponibles pour la formation puis l'utilisation de réseaux de neurones. (42)

3.3 La formation des praticiens

La formation des praticiens est une condition prépondérante à la mise en place réussie d'un SIADM au cabinet dentaire. Selon certains travaux, la formation conditionne l'acceptation de l'introduction d'un SIADM dans l'environnement professionnel des praticiens. (56)

3.4 L'acceptation par les praticiens

Une perturbation trop importante des habitudes du praticien dans son cabinet pourrait constituer un frein à une utilisation pérenne des SIADM. Il a été établi que pour réussir, le SIADM doit fournir une aide réelle aux praticiens, en rendant leurs décisions cliniques plus fiables, plus rapides, plus efficaces et plus faciles sans imposer une charge de temps importante ou des modifications des habitudes de pratique préférées. (57)

De nombreux facteurs peuvent influencer sur les efforts de mise en œuvre, tels que la qualité du management dans la pratique, la réceptivité des cliniciens, la préparation et le

calendrier de la mise en œuvre, une formation adéquate du système d'aide à la décision mis en place et la concordance entre l'aide à la décision et la philosophie de la pratique en général. (57)

Mertz et al en 2015 (56), dans la première étude sur l'introduction de SIAMD basée sur les dossiers électroniques de santé en chirurgie dentaire, dégagent des situations corrélées positivement et négativement avec l'attitude vis à vis des SIADM avant leur mise en place. Le but du travail étant de mener une enquête sur la mise en place d'un SIADM pour les dentistes, hygiénistes et assistantes du groupe WDG aux Etats-Unis en évaluant les compétences et attitudes vis à vis du logiciel avant et après son induction.

Situations où les attitudes sont corrélées positivement vis à vis de l'utilisation du SIAMD avant son introduction:

- Les praticiens sont compétents et satisfaits de l'utilisation de dossiers électroniques de santé.
- Les attitudes sont favorables au changement
- Confiance en soi et son équipe
- Le fait d'avoir des outils pour améliorer la qualité de son travail
- La satisfaction au travail et vis à vis de ses performances ainsi que le contrôle du travail
- L'accompagnement, la sensibilisation et l'importance des incitations liées à la performance

Situations où les attitudes sont corrélées négativement vis à vis de l'utilisation du SIAMD avant son introduction:

- Le fait d'être né aux USA
- L'adoption tardive de la technologie
- Une contrainte physique et temporelle augmentée au travail
- La frustration fréquente, l'épuisement émotionnel, la fatigue et l'épuisement au travail

Cette étude suggère que l'acceptation par les praticiens de logiciels pour les assister dans les diagnostics, repose grandement sur leur capacité à accepter la nouveauté tant d'un point de vu technologique que dans leurs habitudes de travail quotidiennes. Cette capacité d'adaptation peut être liée à des facteurs individuels tels que l'âge ou l'origine culturelle, l'environnement de travail, l'expérience ou encore les capacités physique et

mentale au travail. Les caractéristiques démographiques sont mentionnées bien que faiblement corrélées.

Il paraît cohérent qu'un praticien stressé au travail, qui n'a pas confiance en lui ou en son équipe et qui se sent épuisé, sera moins enclin à l'introduction d'un nouvel outil nécessitant un effort d'adaptation dans son cabinet.

Cependant lors de la poursuite de l'enquête les auteurs estiment qu'après la mise en place du système, il n'existe pas de corrélation positive entre les attitudes et les compétences vis à vis de ce dernier et les données démographiques des cliniciens. Ces constatations éliminaient les employés du groupe proche de la retraite pour lesquels un effet faiblement négatif mais significatif a été mesuré. L'enquête révèle par contre qu'il existe, après mise en oeuvre, une corrélation entre les attitudes favorables et les expériences.

En effet, ces résultats sont cohérents et légèrement plus forts que les corrélations de base, ils indiquent que les opinions sur l'environnement de travail et les attitudes sont devenues plus étroitement corrélées après l'expérience réelle avec les outils.

De plus, l'étude post-introduction a confirmé ce qui avait été établi par le passé, un faible niveau de stress et un faible épuisement (physique et mental) sont corrélés à des attitudes favorable vis à vis du logiciel. Plus on est satisfait de sa performance et de son travail dans l'ensemble, plus on ressent une influence positive sur son travail, et plus le niveau de frustration est faible, plus le lien avec les attitudes positives à l'égard du SIAMD est important.

Pour finir, dans les résultats de cette étude il est rapporté que les motivations des cliniciens à l'égard du SIAMD ont été motivées par l'importance accordée par les cliniciens aux données probantes (le sentiment que le SIAMD leur fait prendre des décisions en accord avec les données acquises de la science) et le sentiment que cet outil contribuait à améliorer les soins et la santé des patients.

A contrario, la rémunération et la pression des pairs n'étaient pas corrélées avec des attitudes favorables à l'utilisation du SIAMD.

Il apparaît, donc, que la formation et l'accompagnement des utilisateurs à l'utilisation de tels outils peuvent être des solutions pour favoriser leur acceptation qui sera motivée, en premier lieu, par une amélioration de la qualité des soins et de la prise en charge globale du patient.

Pour ces enquêtes, Mertz et al se sont focalisés sur les employés du groupe WDG aux Etats-Unis. Pour avoir une vision plus globale de l'attitude des praticiens vis à vis de

l'introduction d'un SIAMD, il faudrait l'étendre à des professionnels issues d'autres franchises où ayant une activité libérale.

3.5 L'acceptation par les patients

Peu de papiers sur ce sujet sont parus à notre connaissance dans le domaine médical. Une publication faisant état de l'attitude des patients vis à vis d'un médecin virtuel chargé de faire l'anamnèse des patient révèle une réaction de répulsion globalement diminuée par certains facteurs psychosociaux tels qu'un jeune âge et une profession ou des études en rapport avec les sciences. (35)

Conclusion :

A l'aide de l'apprentissage profond, les systèmes informatiques d'aide au diagnostic médical sont des outils qui peuvent améliorer la sérénité et la précision des professionnels de santé.

L'état des performances en odontologie est cependant trop faible pour que l'utilisation au quotidien de SAMD développés avec l'apprentissage profond se généralise. Les développeurs devront d'abord surmonter les difficultés engendrées par la faible quantité et qualité des données disponibles pour former les algorithmes. Cependant les possibilités offertes dans d'autres domaines médicaux laissent penser par analogie qu'il n'est question que de temps pour qu'ils soient efficaces en odontologie.

Il conviendra toutefois pour les praticiens de ne pas se laisser dépasser par les avancées, de comprendre leur mode de fonctionnement et de garder un esprit critique vis à vis des réponses de la machine.

En effet, les SAMD semblent se destiner à offrir aux soignants un second avis en quelques secondes plutôt que de faire le travail à leur place.

Bibliographie :

1. McCulloch WS, Pitts W. A logical calculus of the ideas immanent in nervous activity. Bull Math Biol. janv 1990;52(1-2):99-115.
2. Rosenblatt F. The perceptron: a probabilistic model for information storage and organization in the brain. Psychol Rev. 1958;65(6):386-408.
3. Hinton E. Learning Internal Representations by Error Propagation. :49.ICS Report. 1985
4. Patterson J, Gibson A. Deep learning en action : la référence du praticien. Paris: First interactive O'Reilly; 2018. 534 p.
5. Goodfellow I, Pouget-Abadie J, Mirza M, Xu B, Warde-Farley D, Ozair S, et al. Generative Adversarial Nets. :9.NIPS.2014
6. LeCun Y, Bengio Y, Hinton G. Deep learning. Nature. 2015;521(7553):436.
7. Graham B. Fractional Max-Pooling. ArXvid. déc 2014;
8. Lobach DF, Kawamoto K, Anstrom KJ, Russell ML, Woods P, Smith D. Development, deployment and usability of a point-of-care decision support system for chronic disease management using the recently-approved HL7 decision support service standard. Stud Health Technol Inform. 2007;129(Pt 2):861-5.
9. Newman MG. Clinical decision support complements evidence-based decision making in dental practice. J Evid-Based Dent Pract. mars 2007;7(1):1-5.
10. Mendonça EA. Clinical decision support systems: perspectives in dentistry. J Dent Educ. 1 juin 2004;68(6):589-97.
11. Esteva A, Kuprel B, Novoa RA, Ko J, Swetter SM, Blau HM, et al. Dermatologist-level classification of skin cancer with deep neural networks. Nature. 02 2017;542(7639):115-8.
12. Gulshan V, Peng L, Coram M, Stumpe MC, Wu D, Narayanaswamy A, et al. Development and Validation of a Deep Learning Algorithm for Detection of Diabetic Retinopathy in Retinal Fundus Photographs. J Am Med Assoc. 13 2016;316(22):2402-10.
13. Liu H, Li L, Wormstone IM, Qiao C, Zhang C, Liu P, et al. Development and validation of a deep learning system to detect glaucomatous optic neuropathy using fundus photographs. J Am Med Assoc Ophthalmol. 12 sept 2019;
14. Wahab N, Khan A, Lee YS. Two-phase deep convolutional neural network for reducing class skewness in histopathological images based breast cancer detection. Comput Biol Med. 01 2017;85:86-97.
15. Sheikhzadeh F, Guillaud M, Ward RK. Automatic labeling of molecular biomarkers of whole slide immunohistochemistry images using fully convolutional networks. PlosOne. 2018;13(1):e0190783
16. Zieliński B, Plichta A, Misztal K, Spurek P, Brzywczy-Włoch M, Ochońska D. Deep learning approach to bacterial colony classification. PloS One. 2017;12(9):e0184554.

17. McBee MP, Awan OA, Colucci AT, Ghobadi CW, Kadom N, Kansagra AP, et al. Deep learning in radiology. *Acad Radiol.* 2018;25(11):1472-80.
18. Wang J, Yang X, Cai H, Tan W, Jin C, Li L. Discrimination of Breast Cancer with Microcalcifications on Mammography by Deep Learning. *Sci Rep.* juin 2016;6(1):1-9.
19. Cheng J-Z, Ni D, Chou Y-H, Qin J, Tiu C-M, Chang Y-C, et al. Computer-aided diagnosis with deep Learning architecture: applications to breast lesions in US images and pulmonary nodules in CT scans. *Sci Rep.* avr 2016;6(1):1-13.
20. van Ginneken B. Fifty years of computer analysis in chest imaging: rule-based, machine learning, deep learning. *Radiol Phys Technol.* mars 2017;10(1):23-32.
21. Nibali A, He Z, Wollersheim D. Pulmonary nodule classification with deep residual networks. *Int J Comput Assist Radiol Surg.* oct 2017;12(10):1799-808.
22. Lakhani P, Sundaram B. Deep learning at chest radiography: automated classification of pulmonary tuberculosis by using convolutional neural networks. *radiology.* 2017;284(2):574-82.
23. Lakhani P. Deep convolutional neural networks for endotracheal tube position and x-ray image classification: challenges and opportunities. *J Digit Imaging.* août 2017;30(4):460-8.
24. Akkus Z, Galimzianova A, Hoogi A, Rubin DL, Erickson BJ. Deep learning for brain MRI segmentation: state of the art and future directions. *J Digit Imaging.* août 2017;30(4):449-59.
25. Bilwaj Gaonkar, David Hovda, Neil Martin, Luke Macyszyn. Deep learning in the small sample size setting: cascaded feed forward neural networks for medical image segmentation. mars 2016. *Proceeding of the SPIE*
26. Nurse E, Mashford BS, Yepes AJ, Kiral-Kornek I, Harrer S, Freestone DR. Decoding EEG and LFP signals using deep learning: heading TrueNorth. In: *Proceedings of the ACM International Conference on Computing Frontiers - CF '16.* Como, Italy: ACM Press; 2016. : 259-66.
27. Huang Z, Dong W, Duan H, Liu J. A regularized deep learning approach for clinical risk prediction of acute coronary syndrome using electronic health records. *IEEE Trans Biomed Eng.* mai 2018;65(5):956-68.
28. Feng M, Valdes G, Dixit N, Solberg TD. Machine learning in radiation oncology: opportunities, requirements, and needs. *Front Oncol.* 2018;8:110.
29. Miotto R, Li L, Kidd BA, Dudley JT. Deep patient: an unsupervised representation to predict the future of patients from the electronic health records. *Sci Rep.* 17 2016;6:26094.
30. Nurse E, Mashford BS, Yepes AJ, Kiral-Kornek I, Harrer S, Freestone DR. Decoding EEG and LFP signals using deep learning: heading TrueNorth. In: *Proceedings of the ACM International Conference on Computing Frontiers - CF '16.* Como, Italy: ACM Press; 2016. : 259-66.
31. Strodthoff N, Strodthoff C. Detecting and interpreting myocardial infarction using fully convolutional neural networks. *Physiol Meas.* janv 2019;40(1):015001.
32. Tison GH, Sanchez JM, Ballinger B, Singh A, Olgin JE, Pletcher MJ, et al. Passive

- Detection of atrial fibrillation using a commercially available smartwatch. *JAMA Cardiol.* 01 2018;3(5):409-16.
33. Ismail SA, Gibbons DC, Gnani S. Reducing inappropriate accident and emergency department attendances:: a systematic review of primary care service interventions. *Br J Gen Pract.* 1 déc 2013;63(617):e813-20.
 34. Deligiannidis KE. Primary care issues in rural populations. *Prim Care Clin Off Pract.* 1 mars 2017;44(1):11-9.
 35. Spänig S, Emberger-Klein A, Sowa J-P, Canbay A, Menrad K, Heider D. The virtual doctor: An interactive clinical-decision-support system based on deep learning for non-invasive prediction of diabetes. *Artif Intell Med.* sept 2019;100:101706.
 36. Miotto R, Wang F, Wang S, Jiang X, Dudley JT. Deep learning for healthcare: review, opportunities and challenges. *Brief Bioinform.* mai 2017; 19
 37. Cao C, Liu F, Tan H, Song D, Shu W, Li W, et al. Deep learning and its applications in biomedicine. *genomics proteomics bioinformatics.* 2018;16(1):17-32.
 38. Zhang S, Zhou J, Hu H, Gong H, Chen L, Cheng C, et al. A deep learning framework for modeling structural features of RNA-binding protein targets. *Nucleic Acids Res.* févr 2016;44(4):e32-e32.
 39. Kelley DR, Snoek J, Rinn JL. Basset: learning the regulatory code of the accessible genome with deep convolutional neural networks. *Genome Res.* janv 2016;26(7):990-9.
 40. Telenti A, Lippert C, Chang P-C, DePristo M. Deep learning of genomic variation and regulatory network data. *Hum Mol Genet.* 2018;27(R1):R63-71.
 41. Xiong HY, Alipanahi B, Lee LJ, Bretschneider H, Merico D, Yuen RKC, et al. RNA splicing. The human splicing code reveals new insights into the genetic determinants of disease. *Science.* janv 2015;347(6218):1254806.
 42. Hwang J-J, Jung Y-H, Cho B-H, Heo M-S. An overview of deep learning in the field of dentistry. *Imaging Sci Dent.* mars 2019;49(1):1-7.
 43. Yoon DC, Mol A, Benn DK, Benavides E. Digital radiographic image processing and analysis. *Dent Clin North Am.* juill 2018;62(3):341-59.
 44. Miki Y, Muramatsu C, Hayashi T, Zhou X, Hara T, Katsumata A, et al. Classification of teeth in cone-beam CT using deep convolutional neural network. *Comput Biol Med.* 2017;80:24-9.
 45. Yilmaz E, Kayikcioglu T, Kayipmaz S. Computer-aided diagnosis of periapical cyst and keratocystic odontogenic tumor on cone beam computed tomography. *Comput Methods Programs Biomed.* juill 2017;146:91-100.
 46. Lee J-H, Kim D-H, Jeong S-N, Choi S-H. Detection and diagnosis of dental caries using a deep learning-based convolutional neural network algorithm. *J Dent.* oct 2018;77:106-11.
 47. Hiraiwa T, Arijji Y, Fukuda M, Kise Y, Nakata K, Katsumata A, et al. A deep-learning artificial intelligence system for assessment of root morphology of the mandibular first molar on

panoramic radiography. *Dento Maxillo Facial Radiol.* nov 2018;20180218.

48. Du X, Chen Y, Zhao J, Xi Y. A convolutional neural network based auto-positioning method for dental arch in rotational panoramic radiography. In: 2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). IEEE; Honolulu. jul2018: 2615–2618.
49. Lee J-H, Kim D-H, Jeong S-N, Choi S-H. Diagnosis and prediction of periodontally compromised teeth using a deep learning-based convolutional neural network algorithm. *J Periodontal Implant Sci.* avr 2018;48(2):114-23.
50. Krizhevsky A, Sutskever I, Hinton GE. ImageNet classification with deep convolutional neural networks. In: *Proceedings of the 25th International Conference on Neural Information Processing Systems - Volume 1* Lake Tahoe, Nevada: Curran Associates Inc.; 2012: 1097-1105.
51. Terry DA, Snow SR, McLaren EA. Contemporary dental photography: selection and application. *Compend Contin Educ Dent.* oct 2008;29(8):432-6, 438, 440-442 passim; quiz 450, 462.
52. Thanathornwong B, Suebnukarn S. Clinical decision support model to predict occlusal force in bruxism patients. *Healthc Inform Res.* oct 2017;23(4):255-61.
53. Thanathornwong B, Suebnukarn S, Ouivirach K. Decision support system for predicting color change after tooth whitening. *Comput Methods Programs Biomed.* mars 2016;125:88-93.
54. Rana A, Yauney G, Wong LC, Gupta O, Muftu A, Shah P. Automated segmentation of gingival diseases from oral images. In: 2017 IEEE Healthcare Innovations and Point of Care Technologies (HI-POCT), Bethesda nov 2017. p. 144-7.
55. Murata S, Lee C, Tanikawa C, Date S. Towards a fully automated diagnostic system for orthodontic treatment in dentistry. In: 2017 IEEE 13th International Conference on e-Science (e-Science). IEEE; Auckland oct 2017: 1–8.
56. Mertz E, Bolarinwa O, Wides C, Gregorich S, Simmons K, Vaderhobli R, et al. Provider Attitudes Toward the Implementation of Clinical Decision Support Tools in Dental Practice. *J Evid-Based Dent Pract.* déc 2015;15(4):152-63.
57. Mertz E, Wides C, White J. Clinician attitudes, skills, motivations and experience following the implementation of clinical decision support tools in a large dental practice. *J Evid-Based Dent Pract.* mars 2017;17(1):1-12.
58. Xie X, Wang L, Wang A. Artificial neural network modeling for deciding if extractions are necessary prior to orthodontic treatment. *Angle Orthod.* 11 nov 2009;80(2):262-6.
59. Zanella-Calzada LA, Galván-Tejada CE, Chávez-Lamas NM, Rivas-Gutierrez J, Magallanes-Quintanar R, Celaya-Padilla JM, et al. Deep artificial neural networks for the diagnostic of caries using socioeconomic and nutritional features as determinants: Data from NHANES 2013–2014. *Bioeng Basel Switz.* juin 2018;5(2).
60. Szegedy C, Liu W, Jia Y, Sermanet P, Reed S, Anguelov D, et al. Going Deeper with Convolutions. 2015 IEEE Conference on Computer Vision and Pattern Recognition CVPR. Boston jun 2015.

61. Cheng L, Liu Q, Ronzhin A. Advances in Neural Networks – ISNN 2016: 13th International Symposium on Neural Networks, ISNN 2016, St. Petersburg, Russia, July 6-8, 2016, Proceedings. Springer; 2016.
62. Kermany DS, Goldbaum M, Cai W, Valentim CCS, Liang H, Baxter SL, et al. Identifying medical diagnoses and treatable diseases by image-based deep learning. *Cell*. 22 févr 2018;172(5):1122-1131.e9.
63. Agence Nationale d'Accréditation et d'Evaluation en Santé (ANAES). Guide d'analyse de la littérature et gradation des recommandations *Acta Endosc*. avr 1998;28(2):151-5.
64. Haute Autorité de Santé. Projet de grille d'analyse pour l'évaluation de dispositifs médicaux avec intelligence artificielle. Disponible sur: https://www.has-sante.fr/jcms/p_3118247/fr/projet-de-grille-d-analyse-pour-l-evaluation-de-dispositifs-medicaux-avec-intelligence-artificielle
65. Weese J, Lorenz C. Four challenges in medical image analysis from an industrial perspective. *Med Image Anal*. oct 2016;33:44-9.
66. Wainberg M, Merico D, DeLong A, Frey BJ. Deep learning in biomedicine. *Nat Biotechnol*. oct 2018;36(9):829-38.
67. Mupparapu M, Wu C-W, Chen Y-C. Artificial intelligence, machine learning, neural networks, and deep learning: Futuristic concepts for new dental diagnosis. *Quintessence Int Berlin* 1985. 2018;49(9):687-8.
68. Devlin H, Yuan J. Object position and image magnification in dental panoramic radiography: a theoretical analysis. *Dento Maxillo Facial Radiol*. 2013;42(1):299-316.
69. Pauwels R, Araki K, Siewerdsen JH, Thongvigitmanee SS. Technical aspects of dental CBCT: state of the art. *Dento Maxillo Facial Radiol*. 2015;44(1):20140224.

LACÔTE (Titouan). – Système informatique d’aide au diagnostic médical : apport de l’apprentissage approfondi en odontologie.

- 66f. ; ill. ; tabl. ; 69ref. ; 30cm (Thèse : Chir. Dent. ; Nantes ; 2020)

RÉSUMÉ

L’essor actuel des techniques d’apprentissage automatique pour développer des logiciels intelligents ouvre un large champ de perspectives dans le domaine médical, notamment en matière de diagnostic.

Après avoir mentionné les bases techniques utiles à la compréhension des algorithmes d’apprentissage automatique, nous évoquons dans ce travail de thèse les champs d’applications de ces algorithmes dans les systèmes d’aide informatique au diagnostic médical puis nous nous focalisons sur les travaux en la matière concernant l’odontologie. Il apparaît que le domaine du diagnostic médical, plus particulièrement en odontologie, présente des spécificités freinant l’expansion de l’apprentissage profond bien que les perspectives qu’il y offre soient prometteuses.

RUBRIQUE DE CLASSEMENT : Odontologie

MOTS CLES MESH

Système d’aide à la décision clinique – Decision support systems, clinical

Apprentissage approfondi – Deep learning

Intelligence artificielle – Artificial intelligence

Diagnostic assisté par ordinateur – Diagnosis, computer-assisted

Réseaux neuronaux (ordinateur) – Neuronal network (computer)

JURY

Président : Professeur Amouriq Y.

Directeur : Professeur Amouriq Y.

Assesseur : Professeur Weiss P.

Assesseur : Docteur Jordana F.

Assesseur : Docteur Serisier S.

ADRESSE DE L’AUTEUR

21A rue du val saint Martin – 44210 Pornic
titouanl@orange.fr