



République Algérienne Démocratique et Populaire
Ministère de l'enseignement supérieur et de la
recherche scientifique

Université Larbi Tébessi - Tébessa

Faculté des Sciences Exactes et des Sciences de la Nature et de la Vie
Département : Mathématiques et Informatique



Mémoire de fin d'étude
Pour l'obtention du diplôme de MASTER
Domaine : Mathématiques et Informatique
Filière : Informatique
Option : Systèmes d'information

Thème

**L'apprentissage profond(Deep Learning) pour la
classification des lames anapath numérisées**

Présenté Par :
Manseur Ali

Devant le jury :

Mme.Salima Bourougaa	MCB	Université Larbi Tébessa	Président
Mr. Ismail Hadjaj	MAA	Université Larbi Tébessa	Examineur
Mr.Mohammed Gasmi	MAB	Université Larbi Tébessa	Encadreur
Mr.Issam Bendib	MCB	Université Larbi Tébessa	Co-Encadreur

Date de soutenance : 06/2019

ملخص

تعتبر المرحلة التشخيصية في المجال الطبي الأكثر أهمية لأن عملية العلاج بأكملها ستستند إلى هذا التشخيص. تتطلب هذه الخطوة المهمة الكثير من الوقت والجهد خاصةً عندما يحتاج المرء إلى فحص تكميلي. مرض الأورام هو أحد الأمراض التي تتطلب فحصاً مرضياً يتجاوز 15 يوماً، الشيء الذي يؤثر على مرحلة العلاج. هدفنا في هذا العمل هو تسريع عملية استكشاف جزء الشريحة المرضية التي تم اخذها من المريض من خلال المعالجة التلقائية. هذا الأخير يعتمد على رقمنة الشريحة السرطانية في المقام الأول من أجل وضع هذه الصور تحت معالجة تصنيف لإدراجها في الشبكات العصبية التلافيفية. تحقيقاً لهذه الغاية، قدمنا طريقتين مختلفتين، يعتمد كل منهما على التعلم العميق، وقد اقترحنا عدة نماذج مختلفة وفقاً لترتيب الطبقات ومجموعة من المعلمات، من أجل الحصول على أفضل تصنيف ممكن للصور. البيانات المرضية التي تم جمعها من عينات حقيقية.

الكلمات المفتاحية: الصورة، التصنيف، علم الأمراض، الشرائح الافتراضية، سرطان القولون، التعلم العميق، CNN.

Résumé

La phase de diagnostic dans le domaine médical considéré le plus important vu que tout le processus de traitement sera basé sur ce diagnostic. Cette importante étape nécessite beaucoup de temps et d'efforts surtout des lorsqu'on a besoin d'un examen complémentaire. La maladie oncologique est l'une des maladies qui nécessitent un examen anapath qui dépasse 15 jours, la chose qui influence sur l'étape de traitement.

Notre objectif dans ce travail est d'accélérer le processus d'exploration de la pièce anapath par un traitement automatique. Ce dernier basé sur la numérisation de la lame anapath en premier lieu afin de mettre ces images sous un traitement de classification recenser sur les réseaux de neurones convolutionnels.

À cette fin, nous avons introduit deux méthodes différentes, chacune basée sur l'apprentissage en profondeur et nous avons proposé plusieurs modèles différents selon l'ordonnement des couches et un jeu de paramètres, dans le but d'obtenir la meilleure classification possible des images pathologiques recueillies à partir d'échantillons réels.

Les mots clés : Image, classification, pathologie, lames virtuelles, cancer du côlon, apprentissage en profondeur, CNN

Abstract

The diagnostic phase in the medical field considered the most important since the entire treatment process will be based on this diagnosis. This important step requires a lot of time and effort especially when one needs a complementary examination. Oncological disease is one of the diseases that requires anapathes examination that exceeds 15 days, the thing that influences the treatment stage.

Our goal in this work is to speed up the process of exploring the anapathe part by automatic processing. This last one based on the digitization of the anapathe blade in the first place in order to put these images under a classification treatment to list on convolutional neural networks.

To this end, we have introduced two different methods, each based on deep learning and we have proposed several different models according to the ordering of the layers and a set of parameters, in order to obtain the best possible classification of the images. pathological data collected from real samples.

Keywords: Image, classification, pathology, virtual slides, colon cancer, deep learning, CNN

Remerciements

Tout d'abord, on remercie Dieu pour tout

Je tiens à remercier toutes les personnes qui ont contribué au succès et aidé lors de la rédaction de ce mémoire.

Je voudrais dans un premier temps remercier, mes parents pour leur soutien constant et leurs encouragements., je voudrais remercier mes frères et ma famille en général, ainsi que mes camarades de classe d'être ma deuxième famille.

Je voudrais remercier, mes encadreurs de mémoire Dr.M.Gessmi et Dr.issam bendib, pour leur patience, leur disponibilité et leurs bons conseils en particulier ont alimenté ma réflexion.

Je voudrais remercier, mes tous profes, Salima Bourougaa, A.Gattal, F.Hamidane, L.laimeche, A.Ahmim, A.gharbi, A.sahraoui, R.menassel, y.menassel, D.rouabhia, a.gahmous, M.R.laouar....

enfin

Je veux aussi voir mon neveu Safwan à ce stade de l'éducation ou plus

Sommaire

Liste des figures

Liste des tableaux

Introduction générale.....01

CHAPITRE I : classification des images

I.1	Introduction	3
I.2	Définition de l'image	3
I.3	Défèrent formats d'images.....	3
I.3.1	Les images matricielles :	3
I.3.1.1	BMP (Bitmap) :	4
I.3.1.2	TIF ou TIFF (Tagged Image File Format) :	4
I.3.1.3	JPEG (joins Photographic Expert Group):	4
I.3.1.4	JPEG-LS (Lossless JPEG) :	4
I.3.1.5	JPEG 2000 :	5
I.3.1.6	GIF (Graphics Interchange Format) :	5
I.3.1.7	PNG (Protoble Network Graphic) :	5
I.3.2	Les images vectorielles :	5
I.3.2.1	SVG (Scalable Vector Graphics) en français (Graphique vectoriel adaptable) :	6
I.3.2.2	PS (PostScript)/EPSF (Encapsulated PostScript File):	6
I.3.2.3	AI (Adobe Illustrator) :	6
I.3.2.4	FLA/SWF :	6
I.3.2.5	PDF (portable Document Format) :	6
I.3.2.6	PICT (Picture) :	6
I.3.2.7	PCD :	7
I.4	Caractéristiques des images :	7
I.4.1	Pixel :	7
I.4.2	Dimension & Résolution	7
I.4.3	Voisinage.....	8
I.4.4	Niveau de gris.....	8
I.4.5	Contraste.....	9
I.4.6	Luminance	9
I.4.7	Bruit.....	9
I.4.8	Contour	10

I.5 Méthodes de classification	10
I.5.1 Méthodes supervisées	11
I.5.2 Méthodes non supervisées.....	11
I.5.2.1 Le clustering	12
I.6 Classification des images et l'apprentissage machine	13
I.7 Conclusion.....	14

CHAPITRE II : Apprentissage profond

II.1 Introduction	16
II.2 Apprentissage automatique	17
II.2.1 Classification.....	17
II.2.2 Fonction d'erreur et optimisation des hyperparamètres	18
II.2.2.1 Méthodes d'optimisation bayésienne.....	18
II.2.3 Descente stochastique de gradient	19
II.3 Apprentissage profond.....	19
II.3.1 Historique de l'apprentissage profond.....	19
II.3.2 Définition de l'apprentissage profond	23
II.3.3 Fonctionnement de l'apprentissage profond	24
II.4 Domaine d'application de l'apprentissage	25
II.5 Architectures de réseaux de neurones profonds.....	25
II.5.1 Les réseaux de neurones convolutifs (CNN).....	26
II.5.1.1 L'opération de convolution	26
II.5.1.2 Les couches de CNN	28
II.5.1.3 Les paramètres de CNN.....	30
II.5.1.4 Méthode de régularisation	31
II.5.2 Les réseaux de neurones récurrents (RNN)	32
II.5.2.1 C'est quoi un (RNN) ?.....	33
II.5.2.2 Application RNN.....	34
II.5.3 Apprentissage par renforcement.....	34
II.6 Conclusion.....	35

CHAPITRE III : les réseaux de neurones convolutionnels dans le domaine médicale

III.1 Introduction	36
III.2 Définition d'anapath :	36
III.2.1 Lésion	39
III.2.2 La cytopathologie	39
III.3 Prélèvements tissulaires	40
III.3.1 Biopsie.....	40
III.3.1.1 Pourquoi fait-on des biopsies ?.....	40
III.3.1.2 Types de biopsies	40
III.3.1.3 Quels sont les avantages et les risques de biopsie ?	41
III.3.1.4 Quelles sont les limites des biopsies ?.....	42
III.3.1.5 La valeur des biopsies	42
III.4 Outils de l'anatomopathologie.....	43
III.4.1 Examen macroscopique.....	43
III.4.2 Examen microscopique	43
III.4.3 Les lames	44
III.5 Techniques d'étude des tissus.....	45
III.5.1 La fixation	46
III.5.2 Imprégnation et inclusion	47
III.5.3 Coupes et colorations	47
III.6 Les techniques de deep Learning pour le diagnostic pathologie	49
III.6.1 Autre réseau.....	49
III.6.1.1 FCN	49
III.6.1.2 Encodeur automatique (AE).....	49
III.6.1.3 Réseau de croyances profondes (DBN).....	49
III.6.2 Les techniques CNN	49
III.6.2.1 Cancer du sein	49
III.6.2.2 Cancer du poumon.....	50
III.6.2.3 Cancer de la peau.....	50
III.6.2.4 Cancer de la prostate	51
III.6.2.5 Cancer du cerveau	51
III.6.2.6 Cancer colonial.....	51
III.6.2.7 Autre type de cancer.....	52
III.7 Conclusion.....	52

CHAPITRE IV : Implémentation, résultat et évaluation

IV.1 Introduction	54
IV.2 Logiciels et bibliothèques utilisés.....	54
IV.2.1 Python.....	54
IV.2.2 TensorFlow.....	55
IV.2.3 Keras.....	55
IV.2.4 Scikit-learn	55
IV.2.5 ImageDataGenerator	56
IV.3 Configuration utilisée dans l'implémentation.....	56
IV.4 Présentation de la base de données usuelle	56
IV.5 Conception de la méthode proposée	58
IV.5.1 Algorithmes proposés	58
IV.5.2 Méthode 1.....	61
IV.5.2.1 Modèle 1.....	61
IV.5.2.2 Modèle 2.....	62
IV.5.3 Méthode 2.....	63
IV.5.3.1 Modèle 3.....	63
IV.5.3.2 Modèle 4.....	65
IV.6 Expérimentation et résultats	67
IV.6.1 Résultats de méthode 1.....	67
IV.6.2 Résultats de Méthode 2.....	70
IV.6.3 Comparaisons des résultats de deux méthodes.....	72
IV.7 Conclusion.....	73

Liste de figure

<i>Figure I.1 : image matricielle(bitmap).</i>	4
<i>Figure I.2 : image vectorielle.</i>	6
<i>Figure I.3 : Représentation de la lettre a sous la forme d'un groupe de pixels.</i>	7
<i>Figure I.4 : Représentation de dimension d'une image.</i>	7
<i>Figure I.5 : voisinage à 4 et voisinage à 8.</i>	8
<i>Figure I.6 : exemple de niveaux de gris.</i>	8
<i>Figure I.7 : Image avec et sans bruit.</i>	9
<i>Figure I.8 : exemple de contour.</i>	10
<i>Figure I.9 : Principe de la classification.</i>	10
<i>Figure I.10 : apprentissage supervisé.</i>	11
<i>Figure I.11 : apprentissage non supervisé.</i>	12
<i>Figure I.12 : exemple d'application avec clustering.</i>	13
<i>Figure II.1 : Affiliation de Deep Learning (relation entre IA et ML et Deep Learning) ...</i>	16
<i>Figure II.2 : exemple de classification avec machine Learning.</i>	17
<i>Figure II.3 : À gauche le schéma d'un neurone biologique et à droite le schéma du neurone formel de 1943.</i>	20
<i>Figure II.4 : Schéma d'un LTU.</i>	20
<i>Figure II.5 : exemple de fonctionnement de Deep Learning.</i>	24
<i>Figure II.6 : Architecture standard d'un réseau de neurones profond.</i>	26
<i>Figure II.7 : Schéma du parcours de la fenêtre de filtre sur l'image.</i>	27
<i>Figure II.8 : Exemple d'une convolution dont la configuration est : Opération = Argument maximal, pas horizontal = 1 pixel, pas vertical = 1 pixel.</i>	27
<i>Figure II.9 : Pooling avec un filtre 2x2 et un pas de 2.</i>	29
<i>Figure II.10 : Importance du contexte dans la reconnaissance de l'écriture manuscrite. Le mot « défense » est clairement lisible, mais la lettre « n » prise isolément est ambiguë. ...</i>	33
<i>Figure II.11 : exemple d'un agent utilise l'apprentissage par renforcement.</i>	34
<i>Figure III.1: Examen macroscopique d'une pièce opératoire.</i>	44
<i>Figure III. 2: Inclusion manuelle du tissu dans un moule de paraffine.</i>	47
<i>Figure III.3 : Technique histologique : étapes manuelles.</i>	48

<i>Figure III.3 : Coloration hématoxyline-éosine-safran d'une muqueuse de trompe utérine.</i>	48
<i>Figure III.4 : Coupe du tissu étalé sur lame et coloré en hématoxyline-éosine-safran.</i>	48
<i>Figure IV.1 : image pathologie de class « 0 » (no malade).</i>	57
<i>Figure IV.2 : images pathologie de class « 1 » (maladie).</i>	57
<i>Figure IV.3 : La structure de base de données.</i>	58
<i>Figure IV.4 : architecture de model 1.</i>	62
<i>Figure IV.5 : architecture de modèle 2.</i>	62
<i>Figure IV.6 : architecture de modèle 3.</i>	63
<i>Figure IV.7 : exemple table de configuration de test de mode RGB avec la taille 64*64 pour le modèle 3.</i>	64
<i>Figure IV.8 : exemple table de configuration de test de mode GRAY avec la taille 64*64 pour le modèle 3.</i>	64
<i>Figure IV.9 : architecture de modèle 4.</i>	65
<i>Figure IV.10 : exemple table de configuration de test de mode RGB avec la taille 64*64 pour le modèle 4.</i>	66
<i>Figure IV.11 : exemple table de configuration de test de mode GRAY avec la taille 64*64 pour le modèle 4.</i>	66
<i>Figure IV.12 : les résultats d'acc avec déférente valeur de GradientDescentOptimizer pour modèle 1 et modèle 2.</i>	69
<i>Figure IV.13: exemple de comparaison de valeur de loss entre les deux images de taille 64*64 Gris et RGB pour les deux modèles pour nbr epochs =5 (gauche le modèle 3 et a droit modèle 4).</i>	71

Liste de tableaux

Table IV.1 : différent résultats d'acc de modèle 1 pour différent valeur de deux

feat_map.67

Table IV.2 : différent résultats d'acc de modèle 2 pour différent valeur de feat_map (1,2 et3).67_68

Table IV.3 : les résultats d'acc avec différente valeur de GradientDescentOptimizer. ...68_69

Table IV.4 : résultats de méthode 1 avec différente taille et différent mode d'image.70

Table IV.5 : comparaison de résultats de modèle 1 en mode gris d'image.70

Table IV.6 : les résultats de modèles 3 et 4 avec différente taille en mode RGB.71

Table IV.7 : les résultats de modèles 3 et 4 avec différente taille en mode GRAY.71

Table IV.8 : les résultats de méthode 1 pour le mode RGB d'image.72

Table IV.9 : les résultats de méthode 2 pour le mode RGB d'image.72

Table IV.10 : les résultats de méthode 1 pour le mode GRAY d'image.72

Table IV.11 : les résultats de méthode 2 pour le mode GRAY d'image.72

Introduction générale

L'image est une représentation concrète ou abstraite d'un objet, d'un être vivant ou encore d'un concept. Aujourd'hui, l'image constitue l'un des moyens les plus importants qu'on l'utilise pour communiquer avec autrui. C'est un support d'information et un moyen de communication universel dont la richesse du contenu permet aux êtres humains de tout âge et de toute culture de se comprendre. C'est aussi le moyen le plus efficace pour communiquer, chacun peut analyser l'image à sa manière, pour en dégager une impression et d'en extraire des informations précises. En terme numérique elle désigne, dans son sens le plus général, toute image qui a été acquise, traitée et sauvegardée sous une forme codée représentable par des nombres (valeurs numériques).

L'imagerie médicale est certainement l'un des domaines de la médecine qui a le plus progressé au cours des 20 dernières années. Ces découvertes récentes fournissent non seulement un meilleur diagnostic, mais également de nouveaux espoirs pour de nombreuses maladies. Cancer et épilepsie...., il est devenu facile de détecter certaines maladies, en particulier celles qui nécessitent de longues analyses de laboratoire et des spécialistes, grâce à l'intervention de la technologie informatique, qui a raccourci de nombreuses distances, où nous pouvons traiter des images médicales et les classer en un temps record. Cette classification a permis de toucher beaucoup d'autres spécialités et plus particulier d'images qui concernent l'anatomie pathologique, ces derniers ont longtemps consommé trop de temps et des efforts pour la détection des maladies. Les informations extraites de la structure complexe de l'image pathologique sont très utiles pour le diagnostic de nombreuses maladies, y compris la plupart des tumeurs. Il existe une masse d'informations pathologiques complexes comprenant une structure spatiale abondante, divers types de cellules et une variation de la morphologie des cellules dans les images histopathologiques. Traditionnellement, ces caractéristiques sont découvertes et analysées par des pathologistes ayant des expériences cliniques, ce qui prend du temps et des fois inefficacité du diagnostic. En anatomie pathologique, lorsqu'on parle d'image, il peut être question d'une lame vue depuis un microscope ou d'une pièce macroscopique(vision), d'un compte rendu diagnostique (texte), d'une photo d'une lame (image "simple" ou "plate") ou encore d'une lame virtuelle (image de très grande dimension).

Les lames virtuelles constituent une véritable percée technologique depuis les années 2000 avec beaucoup des travaux de recherches, mais ils n'ont pas touché le point sensible du traitement d'image suis sert à classifier des images pathologiques et la détection de certaines maladies sans l'obligation de passer par un traitement durable du laborantin.

Les méthodes de traitement d'images et les techniques d'apprentissages classiques ont prouvées leurs limites face à ce genre de problématique. L'évolution de l'apprentissage automatique a donné l'espoir de résoudre ce type de traitement, mais l'apprentissage profond avec l'amélioration matérielle importante surtout tous qui concerne les cartes graphiques (GPU) a vraiment survenir une révolution dans le traitement d'images. Le deep learning (l'apprentissage en profondeur) est devenu une préoccupation majeure dans tous les domaines, en particulier dans l'analyse des images médicales.

Notre défi dans ce projet est de numériser les lames anapath par des microscopes électroniques dans le but de lancer un test de classification afin de diagnostiquer l'existence d'un cancer de côlon selon une architecture et un algorithme basé deep learning qu'on a propos.

Dans notre travail on a utilisé les réseaux de neurones convolutionnels pour la classification et la détection de l'existence du cancer de côlon à partir d'une base de données qui contiennent des images pathologiques réelles (lames anapath numériser), avec jeux de paramètres et d'architectures CNN dans le but d'augmenter le taux de réussite.

Pour ce faire, on a organisé notre mémoire en quatre chapitres :

- Dans le premier chapitre on a présenté les notions de base sur l'image et leurs classifications en mentionnant les différents types d'image et leurs caractéristiques ainsi qu'un aperçu sur l'apprentissage machine.
- Le deuxième chapitre a été consacré à la description de Deep Learning en vue générale et le réseau de neurones convolutionnels en particulier. On a parlé de leur fonctionnement, les différents types de classifications et on a aussi cité quelques domaines d'application.
- Dans le troisième chapitre on a le consacré pour parler du domaine d'application ou on a donné des notions de base sur l'anatomie pathologique et les différentes techniques d'étude des tissus. Aussi on a discuté discuter quelques travaux connexes.
- Dans le quatrième chapitre, on a montré la partie expérimentale de notre travail et on a discuté les différents résultats obtenus et on a détaillé l'architecture et paramètre choisi.

CHAPITRE I

Classification des images

1 Introduction

L'image est un support d'information très important, et pour cela il est utilisé dans plusieurs domaines comme le domaine médical, à l'aide d'un système de classification automatique on fait la classification des images, aussi la classification des objets, la reconnaissance de visages, etc. Avec deux principales méthodes de classification : l'apprentissage supervisé et l'apprentissage non-supervisé. Pour le type supervisé, chaque image est étiquetée par sa classe d'appartenance. Par contre dans le type non-supervisée les données ne possèdent pas d'étiquettes. Dans ce travail, nous avons essayé de donner un aperçu de l'image, de ses types et de ses caractéristiques, et nous avons parlé de la relation entre la classification des images et l'apprentissage automatique (machine Learning). Dans notre travail on s'intéresse de l'approche supervisée.

2 Définition de l'image

Une des plus anciennes définitions de l'image est celle donnée par Platon : « J'appelle image d'abord les ombres ensuite les reflets qu'on voit dans les eaux, ou à la surface des corps opaques, polis et brillants et toutes les représentations de ce genre » [1].

L'image c'est une représentation visuelle ou bien un ensemble des points qui donne une certaine information, message, résultat, abstraction, objet, être vivant, idée, etc. L'image utilise comme un support d'information dans tous les domaines (télétection, médecine, météo, la géologie, etc.). Quant à la médecine, c'est l'un des moyens les plus importants, utilisés pour le diagnostic et la détection de certaines maladies telles que les images de radiations et d'autres. L'image a plusieurs caractéristiques comme : la précision des couleurs, taille, dimension, luminance, niveaux de gris, etc. Il est divisé en deux types : image du type matricielle et image du type vectorielle.

3 Différents formats d'images

Il y a deux types d'images différentes :

3.1 Les images matricielles :

Image matricielle : appelée aussi **image bitmap**, c'est un ensemble des bits qui spécifie la couleur de chaque pixel dans un tableau rectangulaire de pixels. Mais lorsque vous effectuez un zoom avant, vous constatez une perte de qualité de l'image. Pour résoudre ce problème, vous devez prendre une photo de très grandes tailles, ce qui pose de nombreux problèmes.



Figure I.1 : image matricielle(bitmap) [2]

Les formats d'image matricielle sont les suivants :

3.1.1 BMP (Bitmap) :

Ce format d'image a été inventé pour la première fois par l'équipe de Microsoft et IBM, il est simple à l'utilisation pour programmer avec l'extension 'BMP', il est composé de couleurs entre 2 à 16 millions.

Habituellement, la majorité des fichiers qui utilisent ce format ne sont pas compressés et par conséquent, il n'y a aucune perte de données.

3.1.2 TIF ou TIFF (Tagged Image File Format) :

C'est un format pour les fichiers graphiques de bitmap (raster) et peut contenir n'importe quel format de données. Il a été développé en 1987 par "Aldus", (actuellement affilié à 'Adobe'), le nombre de couleurs composé dans ce format est entre 1 et 16 millions avec un stockage jusqu'à 32 bits par pixels dans le cas de couleurs réelles (True color), ce type de format est flexible. Il est utilisé dans plusieurs domaines comme les appareils photo, les scanners industriels, etc. [2]

3.1.3 JPEG (Joint Photographic Expert Group):

JPEG est une norme qui définit le format d'enregistrement et l'algorithme de décodage pour la représentation numérique compressée d'une image fixe. Il s'agit d'un comité d'experts qui édite des normes de compression pour l'image fixe. La norme communément appelée JPEG, de son vrai nom ISO/CEI 10918-1 UIT-T recommandation T.81, c'est le résultat de l'évolution de travaux qui ont débuté dans les années 1978 à 1980 avec les premiers essais en laboratoire de compression d'images. [1]

Les extensions de ce format sont : .jpg, .jpeg, et le nombre de couleurs composé dans ce format est 16 millions

3.1.4 JPEG-LS (Lossless JPEG) :

L'algorithme '**LOCO-I**' c'est la base de ce format ce pour cela la compression faite sans aucune perte, et il est évalué par le **joint photographique expert groupe**. Mais comme pour toute image matricielle, lorsque vous zoomez, nous remarquons une perte de qualité.

3.1.5 JPEG 2000 :

Le même groupe qui développe le JPEG et le JPEG-LS produit aussi ce format avec des extensions (jp2, j2k, jpf, jpx, jpm, mj2). Le nombre de couleurs compose de ce format est 4 milliards, Il prend également en charge la transparence et l'animation. Ce format peut être compressé avec ou sans perte, il supporte la transparence et l'animation. Peu importe la compression utilisée, les fichiers JPEG2000 sont plus performants que les fichiers utilisant le JPEG « classique », car ils sont de qualité égale pour une taille inférieure. De plus, les contours sont plus nets et les contrastes mieux rendus qu'avec un fichier JPEG « classique ». [2]

3.1.6 GIF (Graphics Interchange Format) :

Très connus sous l'acronyme GIF, en 1987, Compu-Serve et H&R Block mis au point ce format pour permettre le téléchargement d'images en couleur. C'est un format très utilisé sur le web. et leur extension c'est '**.GIF**'. Avec un nombre maximum de couleurs jusqu'à 256 couleurs. Il est sans perte, et aussi supporte la transparence et l'animation. Les fichiers **.gif** sont de petites tailles du fait que ce format ne peut enregistrer que 256 couleurs. Mais seulement 256 couleurs, ce qui est peu par rapport aux autres formats. Son plus gros inconvénient est donc lié à un de ses avantages. [2]

3.1.7 PNG (Portable Network Graphic) :

On peut remplacer le format de GIF avec le format PNG, mais ce n'est qu'une question de temps, comme il est open source, et à l'origine a été produit par une fête W3C avec une seule extension (**PNG**), le nombre de couleurs dans ce type à 16 millions, mais aussi comme pour toute image matricielle, lorsque vous zoomez, vous pouvez remarquer la perte de qualité

3.2 Les images vectorielles :

Comme toute image, l'image vectorielle utilise également la technique pixel, mais comme elle est calculée dynamiquement par le programme, sa position et sa couleur ne sont pas fixes.

Par exemple, pour afficher une ligne, le programme spécifie le point de départ et le point d'accès suivi du chemin à suivre, puis calcule tous les pixels nécessaires pour afficher cette ligne. La même chose s'applique aux formes et aux couleurs plus complexes. [3]

Agrandissement d'une image vectorielle :



Figure I.2 : image vectorielle [2]

Cette technique est souvent utilisée lors du travail avec les palettes graphiques, la création de logos ou de bandes dessinées par exemple.

Les formats d'image vectorielle sont les suivants :

3.2.1 SVG (Scalable Vector Graphics) en français (Graphique vectoriel adaptable) :

En 1999, W3C (World Wide Web Consortium) développe le format SVG qui repose sur le langage XML, il est utilisé aussi pour les animations et la transparence. Leur extension est **.svg**

3.2.2 PS (PostScript)/EPSF (Encapsulated PostScript File):

Format hybride vectoriel /matriciel, il est destiné à l'impression de photographies. EPS est un fichier PS comportant des restrictions supplémentaires. Avec Extensions : **EPS, EPSF**. Il est très bien reconnu par une majorité de systèmes et de lecteurs graphiques. Le principe vectoriel que le format utilise permet l'agrandissement ou la réduction d'images sans perte de qualité. Il n'a d'intérêt que pour les impressions photo par sa qualité, mais ses fichiers sont très lourds. Les fichiers EPS s'ouvrent seulement avec Adobe Illustrator, Freehand ou Adobe Photoshop. [2]

3.2.3 AI (Adobe Illustrator) :

Ce format est parmi les formats standard qui ont été formulés par Adobe, et qui ont eu un rôle important dans la représentation des dessins vectoriels, avec extension : **.ai**. Mais seul Adobe Illustrator est capable d'ouvrir ce genre de fichier.

3.2.4 FLA/SWF :

Ce format est très répandu sur les sites, il est considéré parmi les formats standard qui ont été produits par 'Macromedia', on peut voir ce format d'image à l'intérieur des formats comme mp3, JPEG et même des vidéos

3.2.5 PDF (portable Document Format) :

Adobe crée ce format avec une version simplifiée du format PostScript pour un affichage efficace des documents, peu importe le système utilisé. Leur extension est **PDF**

3.2.6 PICT (Picture) :

Ce format est utilisé de nos jours comme un format par défaut sur Mac OS, il est développé par Macintosh. Leur extension est **.pict**

3.2.7 PCD :

Ce format est développé par Kodak, il est utilisé par PrestaShop. L'un des principes de ce type est d'agrandir ou de réduire les images sans perte de qualité.

4 Caractéristiques des images :

4.1 Pixel :

Le pixel est l'abrégié du mot « Pictures élément », il détermine la base de l'image, car il est considéré comme l'unité de surface. Le pixel est présenté le niveau de gris, et il est lié avec certaines couleurs et aussi une intensité. Le Pixel est le plus petit composant pouvant être manipulé pour l'affichage ou l'impression.

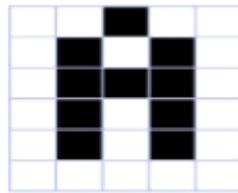


Figure I.3 : Représentation de la lettre a sous la forme d'un groupe de pixels

Dans les images monochromes, les pixels donnent les différences exactes entre eux, ainsi que la même chose pour les images couleur, en fonction de la quantité. Par exemple, un pixel est représenté par trois octets pour chaque couleur, ce qui correspond aux images couleur (RGB).

4.2 Dimension & Résolution

La dimension dans ce cas est la taille de l'image, et on le trouve sous la forme d'une matrice portant des valeurs numériques représentant l'intensité de la lumière appelée pixel, et pour obtenir le nombre total de pixels dans l'image, on multiplie le nombre de lignes dans le nombre de colonnes.

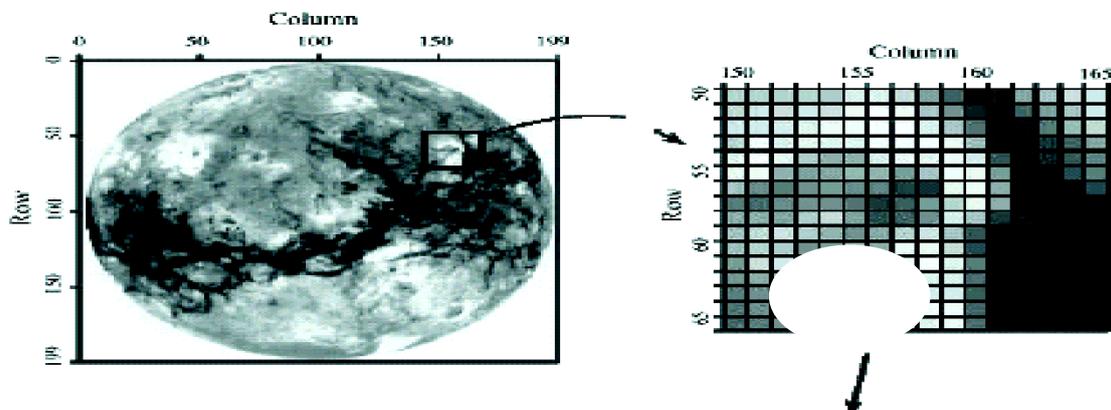


Figure I.4 : Représentation de dimension d'une image

Par contre la résolution est la clarté ou la finesse de détails atteinte par un moniteur dans la production d'images. Sur les moniteurs d'ordinateurs, la résolution est exprimée en nombre de pixels par unité de mesure (pouce ou centimètre). On utilise aussi le mot résolution pour désigner le nombre total de pixels affichables horizontalement ou verticalement sur un moniteur, plus grand est ce nombre, meilleure est la résolution. [4]

4.3 Voisinage

L'image est un ensemble de pixels qui s'entrelacent et repose sur ce principe, la surface de l'image est formée de deux : forme rectangle ou d'une forme hexagone, ce qui donne la notion de voisinage, où le voisinage de pixels est formé par le groupe de pixels autour de ce même pixel. Où cela les opérateurs de voisinage prennent en compte l'information portée par les pixels voisins du pixel étudié.

Nous mentionnons deux types de voisinage :

- Voisinage à 4
- Voisinage à 8

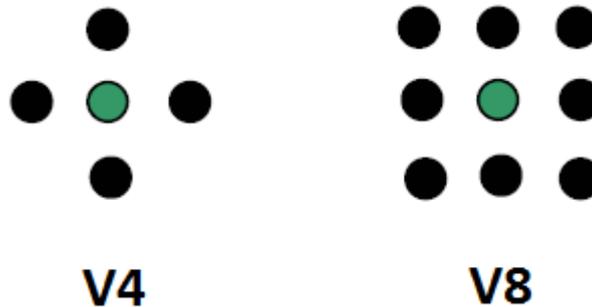


Figure I.5 : voisinage à 4 et voisinage à 8. [5]

4.4 Niveau de gris

Le niveau de gris est défini en tout point où ce dernier porte la valeur de l'intensité lumineuse, de sorte que la couleur du pixel prend des valeurs allant du noir au blanc. C'est-à-dire pour représenter des images en niveaux de gris, chaque pixel peut prendre une valeur comprise entre 0 et 255.

Plus le nombre de bits reflétant la couleur de chaque pixel de l'image est grand, plus les niveaux de gris sont élevés



Figure I.6 : exemple de niveaux de gris [1]

4.5 Contraste

C'est l'opposition marquée entre deux régions d'une image, plus précisément entre les régions sombres et les régions claires de cette image. Le contraste est défini en fonction des luminances de deux zones d'images.

Si L_1 et L_2 sont les degrés de luminosité respectivement de deux zones voisines A_1 et A_2 d'une image, le contraste 'C' est défini par le rapport : $C=L_1-L_2/L_1+L_2$. [6]

4.6 Luminance

L'image est définie comme un ensemble de points où elle se caractérise par différents degrés de luminosité, ce dernier étant défini par l'intensité lumineuse d'une surface à travers la zone visible de cette surface.

Dans le cas de l'observateur distant, la notion de luminance est utilisée comme un télégramme correspondant à la luminosité de l'objet.

Les caractéristiques de la meilleure Luminance sont :

1. Des images lumineuses (brillantes)
2. Le degré de contraste est meilleur : évitez les images où la plage de contraste allant du blanc au noir, ces images entraînent une perte de détail dans les parties sombres ou claires.
3. Aucun de parasites.

4.7 Bruit

Montrée après le processus d'émission et de réception sous la forme d'un signal clair dans l'image où de ce que l'on appelle du parasite, cette variante s'appelle la différence de densité de pixels si on la compare au pixel qui l'entoure, cela produit du bruit sous forme d'erreurs causées par des capteurs électroniques ou de scanners de moins bonne qualité.

Ils apparaissent en petits points à la surface de l'image, comme illustrée dans la figure suivante.



Image avec bruit



Image sans bruit

Figure I.7 : Image avec et sans bruit

4.8 Contour

L'image est composée d'objets et n'interfère pas les uns avec les autres en raison de l'existence de frontières qui les séparent les uns des autres et sont appelées le terme "contour", ou entre les deux pixels qui représentent une grande différence au niveau du gris

Sur la base des points qui séparent deux textures différentes dans l'image ou plutôt de la neutralisation, l'extraction ou la composition du "contour"

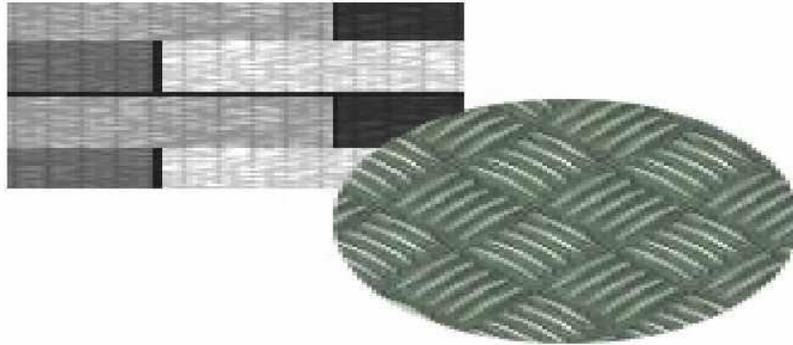


Figure I.8 : exemple de contour

5 Méthodes de classification

La classification pour l'image est une attribution de chaque pixel dans une classe (étiquette), donc pour cela on utilise deux méthodes de classification (supervisée et non-supervisée) et nous ne pouvons pas oublier la mention le troisième type qui s'appelle apprentissage par renforcement

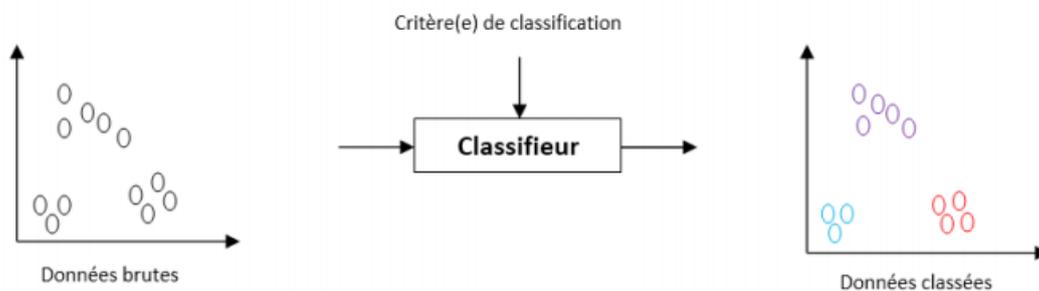


Figure I.9 : Principe de la classification.

5.1 Méthodes supervisées

Un apprentissage supervisé permet d'analyser les données préalables et produire une fonction de prédiction qui peut être utilisée pour traiter de nouvelles instances, acquérir des nouvelles connaissances et généralement unifier l'intelligence.

La machine est fournie avec des échantillons d'entrées qui sont étiquetés avec les sorties qui attendent.

Cette méthode a pour but d'enseigner l'algorithme, c'est-à-dire qu'il devient une comparaison de sa sortie réelle avec le reste des sorties attendues et ceci afin de changer le modèle ou plutôt de le corriger en fonction de l'existence d'erreurs. L'utilisation de la supervision de l'apprentissage permet de prédire les valeurs de nommage sur de nouvelles données.

En ce qui concerne le champ des images, ces méthodes ont la capacité de faire progresser la connaissance des catégories et avant l'identification des éléments de l'image et il existe des algorithmes de classification des pixels, notamment de Bayes. K-PPV ou réseaux de neurones

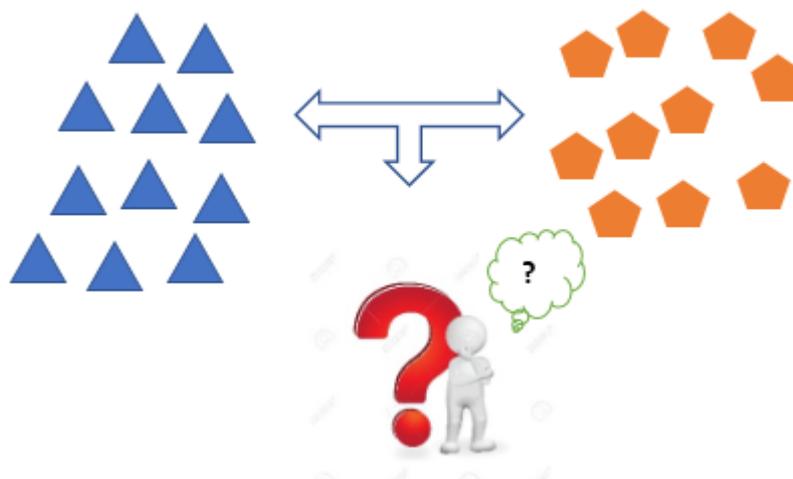


Figure I.10 : apprentissage supervisé

5.2 Méthodes non supervisées

Il vise à concevoir un modèle structurant l'information. La différence ici est que les classes (ou catégories) des données d'apprentissage ne sont pas connues, c'est ce que l'on cherche à trouver.

Les données de l'apprentissage non supervisé ne sont pas distinctives, c'est-à-dire que l'algorithme d'apprentissage trouve ses données d'entrée partagées en points. Étant donné que le nombre de données non classifiées est supérieur aux données spécifiées, les méthodes

d'apprentissage automatisées facilitant l'apprentissage non supervisé sont particulièrement utiles.

L'objet d'un apprentissage non contrôlé peut-être simple, car les modèles cachés dans le jeu de données sont découverts et en même temps son objectif d'apprentissage, ce qui permet à la machine intelligente de découvrir les représentations nécessaires, ce dernier étant automatiquement conçu pour classer les données brutes.

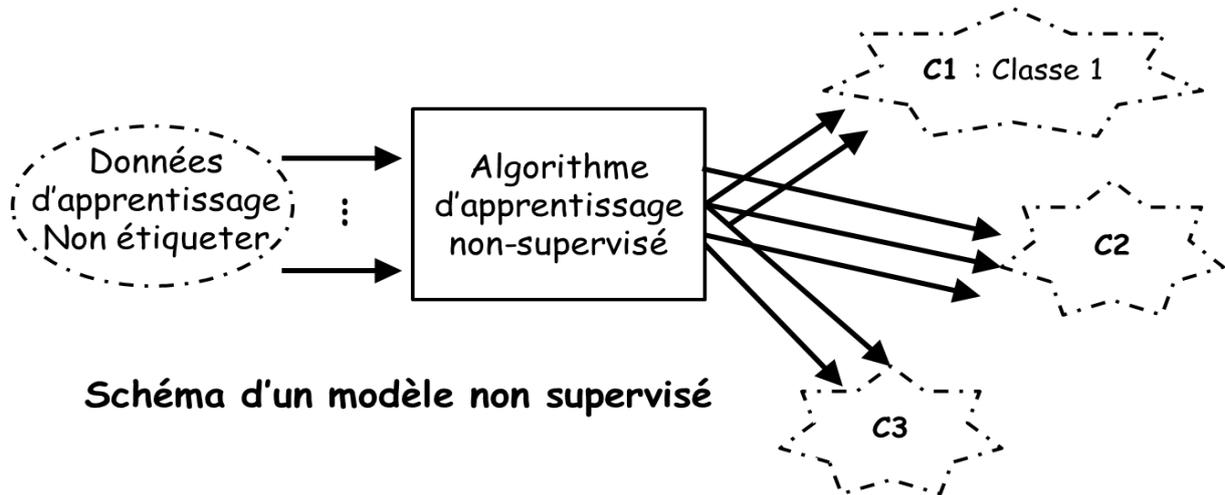


Figure I.11 : apprentissage non supervisé

Différentes tâches sont associées à l'apprentissage non supervisé

- **Clustering** (l'apprentissage non supervisé est très souvent synonyme de **clustering**)
- **Règles d'association** : analyser les relations entre les variables ou détecter des associations.
- **Réduction de dimensions.**

5.2.1 Le clustering

- ❑ Les techniques de **clustering** cherchent à décomposer un ensemble d'individus en plusieurs sous-ensembles les plus homogènes possible
 - On ne connaît pas la classe des exemples (nombre, forme, taille).
- ❑ Pour établir l'équilibre, il minimise l'inertie à l'intérieur des classes et maximise celle entre les sous-groupes afin de bien les différencier
 - L'objectif peut être de hiérarchiser ou de répartir les données.
- ❑ Les méthodes sont très nombreuses, typologies généralement employées pour les distinguer
 - Méthodes de partitionnement / Méthodes hiérarchiques.
 - Avec recouvrement / sans recouvrement.

- Autre : incrémental / non incrémental.
- Comme un exemple d'application, l'imagerie spatiale compresse ses données en organisant sous forme de clusters les différents éléments présents sur chaque image, comme des forêts, des villes ou des zones agricoles par exemple.
 - Cela permet de réduire la taille des paquets de données qui sont, sinon, trop lourds.

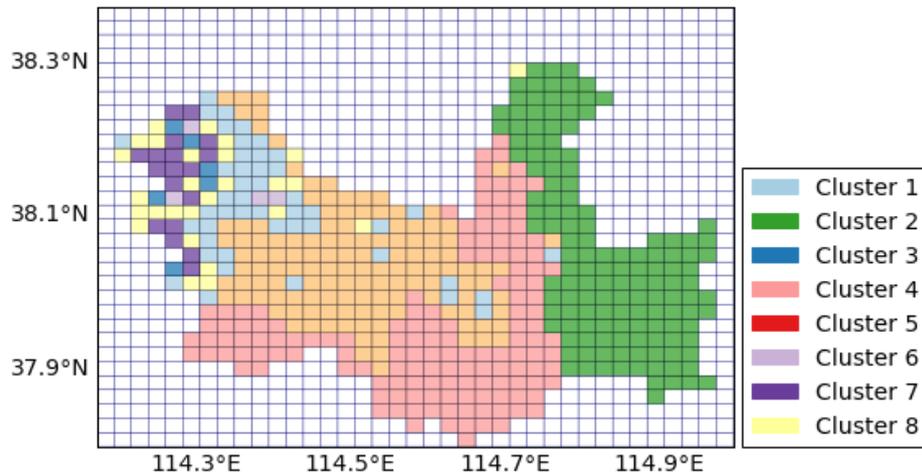


Figure I.12 : exemple d'application avec clustering

6 Classification des images et l'apprentissage machine

Avant l'invention de la machine, tout a été fait de manière manuelle, car ce dernier ne pouvait pas connaître les objets dans les images ou le comptage des sons et les distinguer comme le monde réel est une collection de données sous forme de sons ou de pixels présents dans une image instable remplie de complexité et de bruit

Pour ce qui est de la machine, l'image est représentée par un ensemble de chiffres reflétant la luminosité (ou la couleur) de chaque pixel. Quant au son, il voit les numéros de série dans un ordre spécifique indiquant la pression de l'aire à chaque instant.

La question est de savoir comment la machine transforme le signal audio en un groupe de mots au milieu de tout ce bruit et comment elle peut distinguer le ton du locuteur et les caractéristiques de sa voix. Comment la machine détermine-t-elle l'apparence d'un chat ou d'une table dans un schéma d'un ensemble d'images parmi l'apparente différence d'aspect avec le reste des objets environnants ?

Les programmes conçus ne sont pas très efficaces ni donnent un résultat précis dans tous les cas, ce qui a incité l'apprentissage automatique (ou apprentissage automatique), qui a obligé toutes les grandes entreprises spécialisées dans le domaine de l'internet à atteindre ce niveau d'apprentissage.

Où il a été utilisé pour filtrer le contenu et organiser les réponses lors de la recherche ou les informations qui intéressent chaque utilisateur et pour fournir des recommandations et d'autres.

Le système d'entraînable est considéré comme une boîte noire dont l'entrée est une image, un son ou un texte, et la sortie est la classe de l'objet dans l'image, le mot parlé ou le sujet du texte (système de classification ou reconnaissance de formes).

Le cas le plus couramment utilisé est celui où l'apprentissage automatisé est supervisé : par exemple, nous affichons une personne à l'entrée et à la sortie, nous donnons une image de la même personne, puis nous montrons une photo d'un animal avec la sortie souhaitée du même animal. Après chaque processus, la machine améliore ses paramètres pour obtenir des résultats plus précis dans le futur. Plus le nombre d'exemples ou de processus réalisés par la machine est grand, plus elle a la capacité de procéder à une classification plus précise.

Mais il est intéressant qu'ils classent des images qui n'ont pas été rencontrées dans la phase d'apprentissage, c'est ce que nous appelons la capacité de généralisation

Il n'y a pas si longtemps, les systèmes de reconnaissance de formes traditionnelles étaient constitués de deux blocs : le premier était un extracteur distinctif/de caractéristiques (feature extractor en anglais) et le second était constitué d'un classer simple et facile à gérer. Pour l'extracteur de caractéristiques, il est programmé manuellement et convertit le tableau de nombres représentant l'image en une série de nombres et un vecteur distinct, chacun étant lié à la présence ou à l'absence d'un motif simple dans l'image.

Ce vecteur envoie ensuite le vecteur au classer, qui calcule ensuite la somme pondérée des attributs(caractéristiques) en multipliant chaque nombre par son poids (positif ou négatif) avant de le collecter. Ici, la comparaison est faite : si le total est supérieur à la limite, il est facile d'identifier la catégorie. Les poids forment une sorte de "prototype" pour la classe où le vecteur élément est comparé

7 Conclusion.

Nous avons consacré ce chapitre à la présentation de notion d'image et leurs différents formats et leurs caractéristiques, et on a parlé aussi sur les méthodes des classifications ainsi que leurs intérêts dans le domaine d'imagerie et l'apprentissage machine. Dans le deuxième chapitre, on va bien détailler l'apprentissage profond et plus précisément des réseaux de neurones convolutionnels et leur utilisation dans la classification des images.

CHAPITRE II

Apprentissage profond

1 Introduction

Beaucoup d'entre nous sont incapables de faire la distinction entre intelligence artificielle (IA), apprentissage automatique (ML) et apprentissage profond (DL), mais si les trois termes sont souvent utilisés de manière interchangeable, ils ne font pas référence aux mêmes choses.

Voici une image qui tente de visualiser la distinction ou bien la relation entre eux :

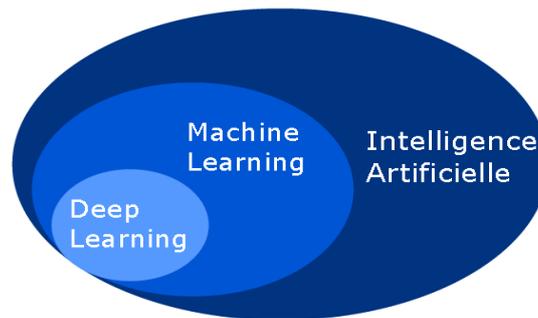


Figure II.1 : Affiliation de Deep Learning (relation entre IA et ML et Deep Learning)

L'apprentissage automatique se concentre uniquement sur la résolution des problèmes concrets. Il faut également quelques idées de l'intelligence artificielle. L'apprentissage automatique passe par les réseaux de neurones conçus pour imiter les capacités de prise de décision de l'homme. Les outils et techniques de ML sont les deux sous-ensembles étroits centrés uniquement sur l'apprentissage en profondeur. Nous devons l'appliquer pour résoudre tout problème qui nécessite une réflexion, qu'il soit humain ou artificiel. Tout réseau de neurones profonds comprendra trois types de couches :

- La couche d'entrée
- La couche cachée
- La couche de sorties

Nous pouvons dire que l'apprentissage en profondeur est le terme le plus récent dans le domaine de l'apprentissage automatique. C'est un moyen de mettre en œuvre la Machine Learning.

Nous utilisons un algorithme machine pour analyser les données, en tirer des leçons et prendre des décisions éclairées en fonction de ce qu'elles ont appris. Fondamentalement, l'apprentissage en profondeur est utilisé en couches pour créer un « réseau de neurones artificiel » capable d'apprendre et de prendre des décisions intelligentes par lui-même. Nous pouvons dire que l'apprentissage en profondeur est un sous-domaine de l'apprentissage automatique.

Différentes architectures de réseau de neurones sont utilisées dans DL, chacune avec ses propres avantages et inconvénients. Les réseaux de neurones convolutionnels ou CNN pour «

Convolutional Neural Network » sont une extension des MLP permettant de répondre efficacement aux principaux défauts des MLP. Ils sont conçus pour extraire automatiquement les caractéristiques des images d'entrée, sont invariants à de légères distorsions de l'image, et implémentent la notion de partage des poids permettant de réduire considérablement le nombre de paramètres du réseau.

2 Apprentissage automatique

"L'apprentissage automatique (machine Learning) est le champ de l'IA qui permet à une machine (au sens large) d'apprendre. C'est-à-dire, d'améliorer progressivement ses performances sur une tâche spécifique en se basant sur des données, le tout sans être explicitement programmé pour résoudre cette tâche." **L. Samuel, 1959(IBM)**

L'apprentissage automatique est un moyen d'analyser des données. Il est également considéré comme une branche de l'intelligence artificielle construite sur l'idée que les systèmes peuvent apprendre des données, déterminer des modèles et prendre des décisions de manière autonome, avec une intervention humaine minimale.

En raison des nouvelles technologies informatiques, l'apprentissage par la machine n'est pas comparable à l'apprentissage par la machine du passé. Il est né de la reconnaissance des formes et de la théorie selon laquelle les ordinateurs peuvent apprendre sans être programmés pour effectuer des tâches spécifiques. Les chercheurs intéressés par l'intelligence artificielle ont voulu savoir si les ordinateurs pourraient apprendre des données. L'aspect itératif de l'apprentissage automatique est important, car, à mesure que les modèles sont exposés à de nouvelles données, ils peuvent s'adapter indépendamment. Ils tirent des enseignements de calculs antérieurs pour produire des décisions et des résultats fiables et reproductibles. C'est une science qui n'est pas nouvelle, mais qui a pris un nouvel élan.

2.1 Classification

La classification est une méthode qui consiste à diviser un grand groupe de données en un certain nombre de catégories souhaitées et distinctes, dans lesquelles on peut attribuer une classification à chaque catégorie.

En d'autres termes, la classification appartient à la catégorie de l'apprentissage supervisé, qui présente l'avantage de fournir les objectifs des données d'entrée. Les applications de classification sont présentées dans de nombreux domaines, notamment l'accréditation de crédit, le diagnostic médical, le marketing ciblé, etc.

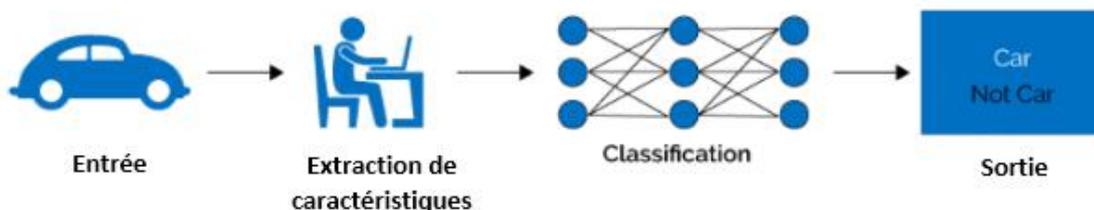


Figure II.2 : exemple de classification avec machine Learning

Comme son nom l'indique, la classification est obtenue en classant les objets dans des sous-catégories à partir d'un groupe général, mais la machine peut-elle distinguer les personnes ou les animaux à l'aide des images, ou peut-elle distinguer et classer les textes en fonction de leur contenu ? Oui, la machine peut effectuer toutes les classifications à l'aide des données et les algorithmes appropriés, et donner des résultats précis en peu de temps. Donc elle est un exemple de reconnaissance de forme.

Mais dans machine Learning, la classification donner un problème d'identification une nouvelle observation à quel groupe de catégories (sous-populations) appartient, sur la base d'un ensemble de données de formation contenant des observations et dont les catégories sont connues.

2.1.1 Types de classification

La classification est de deux types :

Classification binaire : Cette classification est suivie si nous devons diviser et classer les données disponibles en deux catégories différentes (en identifiant le groupe auquel chacune appartient) et la base de la règle de classification. Inclut les contextes nécessitant de décider si l'élément a une propriété spécifique, une propriété spécifique ou une classification binaire typique, par exemple, si une personne est malade et que l'on souhaite diagnostiquer le type de maladie, "x" s'il est infecté ou non.

Classification multi classe : Dans ce cas, le nombre de classes devrait être supérieur à deux, en fonction du large éventail de données disponibles. Dans l'apprentissage automatique, la classification de classes multiples ou multi-frontières est un problème de classification dans l'une ou plusieurs des trois catégories, en dépit de l'existence d'algorithmes de classification autorisant l'utilisation de plus de deux classes.

2.2 Fonction d'erreur et optimisation des hyperparamètres

Les hyperparamètres sont essentiels dans l'apprentissage automatique, car elles sont générées souvent des modèles avec des performances très différentes.

Le réglage des hyperparamètres d'apprentissage automatique est une tâche fastidieuse, mais cruciale, car la performance d'un algorithme peut dépendre fortement du choix des hyperparamètres, il est effectué à l'aide de méthodes automatisées qui visent à trouver les hyperparamètres optimaux en moins de temps, en utilisant une recherche éclairée, sans aucun effort manuel au-delà de la configuration initiale.[7]

2.2.1 Méthodes d'optimisation bayésienne

En bref, l'optimisation bayésienne trouve la valeur qui minimise une fonction objective en construisant une fonction de substitution (modèle de probabilité) sur la base des résultats d'évaluation antérieure de l'objectif. L'optimisation de la substitution est moins chère que celle de l'objectif. Le concept est le suivant : limitez les évaluations coûteuses de la fonction objective en choisissant les valeurs d'entrée suivantes en fonction de celles qui ont bien fonctionné dans le passé.

Dans le cas de l'optimisation d'hyperparamètres, la fonction objective est l'erreur de validation d'un modèle d'apprentissage automatique utilisant un ensemble d'hyperparamètres. L'objectif est de trouver les hyperparamètres qui génèrent l'erreur la plus faible sur le jeu de validation, dans l'espoir que ces résultats se généralisent au jeu de test. L'évaluation de la fonction objective est coûteuse, car elle nécessite l'apprentissage du modèle d'apprentissage automatique avec un ensemble spécifique d'hyperparamètres. Le réglage bayésien de l'hyperparamètre utilise un modèle de probabilité constamment mise à jour pour se « concentrer » sur des hyperparamètres prometteurs en se basant sur les résultats antérieurs. [7]

2.3 Descente stochastique de gradient

La descente de gradient stochastique (souvent abrégée SGD), également appelée descente de gradient incrémental, est connue une méthode itérative pour optimiser une fonction évolutive, une approximation stochastique de l'optimisation de la descente de gradient. Elle est appelée stochastique en raison de la sélection aléatoire d'échantillons. [8]

Dans la mesure où une itération de l'algorithme de descente de gradient nécessite une prédiction pour chaque instance du jeu de données d'apprentissage, la gestion de plusieurs millions d'instances peut s'avérer longue. Dans les situations où vous avez de grandes quantités de données, vous pouvez utiliser une variation de descente de gradient appelée descente de gradient stochastique. Dans cette variante, la procédure de descente de gradient décrite ci-dessus est exécutée, mais la mise à jour des coefficients est effectuée pour chaque instance d'apprentissage, plutôt qu'à la fin du lot d'instances. L'apprentissage peut être beaucoup plus rapide avec une descente de gradient stochastique pour des jeux de données d'entraînement très volumineux et, souvent, vous n'avez besoin que d'un petit nombre de passages dans le jeu de données pour atteindre un jeu de coefficients satisfaisant ou suffisant. [9]

3 Apprentissage profond

3.1 Historique de l'apprentissage profond

- 1943 - Le premier modèle mathématique d'un réseau de neurones

Au début de 1943, Walter Pitts et Warren McCulloch ont créé un modèle informatique basé sur les réseaux de neurones du cerveau humain, utilisant un ensemble d'algorithmes basés sur les mathématiques pour imiter la pensée humaine. Ce modèle était appelé "logique de seuil". Les travaux sur "l'apprentissage en profondeur" se sont poursuivis en se reliant à une phase de fluctuation de l'intelligence artificielle

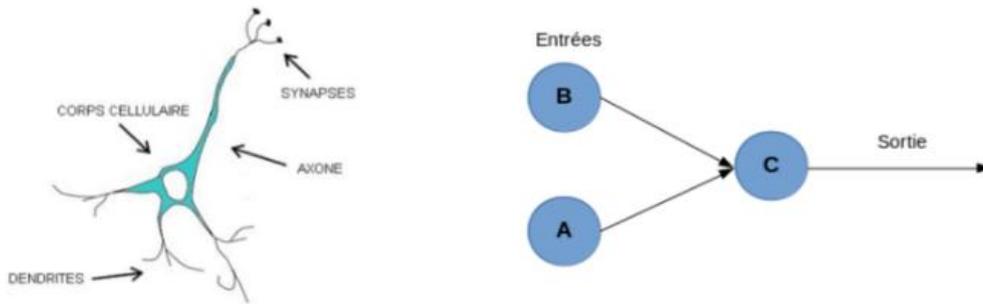


Figure II.3 : À gauche le schéma d'un neurone biologique et à droite le schéma du neurone formel de 1943.

1950 - la prédiction de l'apprentissage automatique.

Turing, un mathématicien qui a brisé les codes pendant la Seconde Guerre mondiale, a prédit le développement de l'apprentissage automatique en 1947. En 1950, il a inventé une machine similaire et a toujours parlé de "machines informatiques et d'intelligence" et a mis au point un "test de Turing" afin de déterminer si l'ordinateur pouvait "penser".

1952 - Premiers programmes d'apprentissage automatique.

Arthur Samuel a continué à créer les premiers programmes d'apprentissage informatique. Et a commencé à montrer les fonctionnalités d'apprentissage à travers le jeu "dames", ce qui a permis à l'ordinateur de corriger ses erreurs et de trouver de meilleurs moyens de gagner. Ce fut l'un des premiers exemples d'apprentissage automatique.

- 1957 - Jeter les bases des réseaux de neurones profonds

En 1957, au Cornell Aviation Laboratory, Rosenblatt écrivit un article intitulé "La perception perspective et automate de reconnaissance" dans lequel il déclarait qu'il créerait un système capable d'apprendre à reconnaître les similitudes ou les identités entre les modèles d'informations visuelles, électriques ou tonales de la même manière aux processus cognitifs du cerveau. Cette idée a jeté les bases de l'apprentissage ascendant et a été largement diffusée en tant que base des réseaux de neurones profonds (DNN).

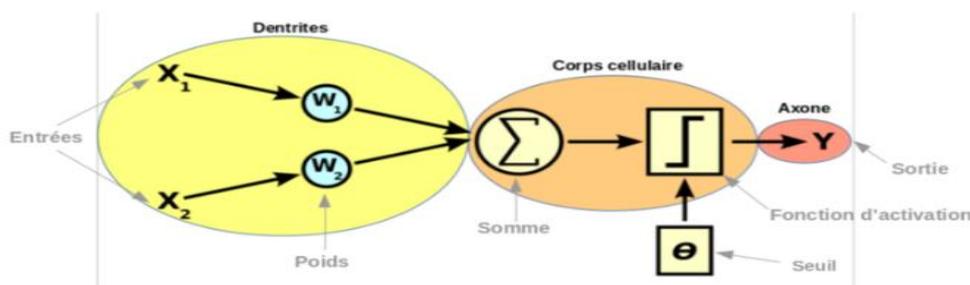


Figure II.4 : Schéma d'un LTU.

- 1959 - Découverte de cellules simples et complexes

En 1959, David Hubble et Torsten Wiesel ont découvert des cellules simples et complexes. Ces activités biologiques ont été un facteur positif dans le domaine de l'apprentissage en profondeur, de nombreux réseaux de neurones artificiels (RNA) étant inspirés par les observations biologiques.

- 1960 - Théorie du contrôle

En 1960, Henry J. Kelley est reconnu pour avoir développé les bases d'un modèle continu à propagation arrière. Deux ans plus tard, plus précisément en 1962, Stuart Dreyfus développa une version simple basée uniquement sur la règle de chaîne., mais le concept de back propagation, censé s'étendre au-delà des erreurs à des fins de formation, resta inefficace jusqu'en 1985.

1965 - les premiers réseaux d'apprentissage en profondeur.

Les efforts se sont poursuivis, notamment ceux d'Alexey Grigoryevich Ivakhnenko, qui a travaillé sur des algorithmes d'apprentissage en profondeur et mis au point une méthode de traitement des données. Valentin Grigor'evich Iapa a mis au point les techniques de cybernétique et de criminalistique, toutes datant de 1965. Ces modèles ont été utilisés avec des fonctions d'activation multidisciplinaire (équations complexes), puis analysée statistiquement.

Au cours des années 1970, un groupe de personnes a poursuivi ses recherches dans ce domaine, mais sans aucun financement.

- 1979-80 - Une ANN apprend à reconnaître les schémas visuels

Merci à Fukushima, qui a créé un réseau de cellules neuronales Neocognitron, capable d'apprendre et d'identifier des modèles visuels et d'être utilisé dans la reconnaissance de caractères manuscrits et d'autres modèles, voire dans le traitement de langages naturels. Ses travaux l'ont amené à développer les premiers réseaux de neurones transformationnels, basés sur la régulation du cortex visuel chez l'animal. 1982 - Création des réseaux Hopfield

Hopfield Networks est un réseau de neurones fréquent qui fonctionne comme un système de mémoire pouvant être rappelé et qui reste un outil de mise en œuvre commun pour l'apprentissage en profondeur au cours de ce siècle.

- 1985 - Un programme apprend à prononcer des mots anglais

En 1985, Terry Segnovsky crée le programme "NETtalk" qui permet la prononciation des mots anglais et parvient à s'améliorer avec le temps.

- 1986 - Amélioration de la reconnaissance de forme et de la prédiction de mots

En 1986, Rohlhart, Hinton et Williams ont publié un article intitulé "Représentations de l'apprentissage par les erreurs rétrogrades", qui montrait comment les réseaux de neurones existants pourraient être grandement améliorés pour de nombreuses tâches telles que la

reconnaissance des formes, la prédiction de mots, etc. Il était considéré comme le père spirituel de l'apprentissage en profondeur.

- 1989 - Q-Learning et les machines lisent les chiffres manuscrits

En 1970. C'est à ce moment-là que Seppo Linnainmaa a rédigé une thèse de maîtrise incluant le code FORTRAN pour la propagation postérieure. Ce concept n'a été mis en oeuvre qu'en 1985. Rumelhart, Williams et Hinton ont démontré que le refoulement du réseau de neurones pouvait fournir des représentations "intéressantes" de la distribution, ce qui posait la question de savoir si la compréhension humaine était basée sur une logique symbolique. Ou représentation distribuée.

En 1989, Yann LeCun a identifié la première présentation pratique de la dépression inverse, combinant neurotransmetteurs et propagation des chiffres « manuscrits ». Ce système a permis de lire nombre de chèques manuscrits 1993 - une tâche d'apprentissage très profond est résolue.

En 1993, l'informaticien allemand Schmidopfer résolut la tâche de "l'apprentissage en profondeur" qui nécessitait plus de 1000 couches dans le réseau de neurones répété.

- 1995 - Machines à vecteurs de support

SVM est essentiellement un système d'identification et de planification de données similaires. Il peut être utilisé pour classer des textes, reconnaître des caractères manuscrits et classer des images pour un apprentissage approfondi

1997 - Proposition de mémoire à long terme

1998 - Apprentissages par gradients

2009 - Lancement d'ImageNet.

ImageNet a été lancé en 2009 par « Fei Fei Lee », professeur et directeur du laboratoire d'intelligence artificielle de l'Université de Stanford.

- 2011 - Création d'AlexNet

Son succès a commencé à relancer le réseau de neurones dans la communauté d'apprentissage en profondeur.

- 2012 - l'expérience de chat

" l'expérience de chat " a été un grand pas en avant. Un réseau de neurones réparti sur des milliers d'ordinateurs a été utilisé et 1 000 000 d'images non en attente - capturées au hasard sur YouTube - ont été détectées et analysées. Ils ont constaté que le programme avait appris à reconnaître et à reconnaître les chats et que la proportion de tentatives d'apprentissage s'était considérablement améliorée.

- 2014 - DeepFace

Il a été développé en 2014 et le système de médias sociaux profonds - DeepFace - utilise des réseaux de neurones pour identifier les visages avec une précision de 97,35%.

- 2014 - Réseaux d'adversaires génératifs (GAN)

Il a été introduit par une équipe de chercheurs dirigée par Ian Goodfellow en 2014. Le réseau GAN utilise deux réseaux concurrents : le premier prend les données et tente de créer des échantillons non caractéristiques, le second reçoit les données et les échantillons générés et doit déterminer si chaque point de données est correct ou créé.

- 2016 - Produits d'apprentissage automatique puissants

Certaines sociétés, telles que Cray Inc, ont été en mesure de fournir des produits et des solutions puissants en machines et en apprentissage en profondeur. Un exemple est l'utilisation du logiciel de réseau neuronal de Microsoft sur des superordinateurs équipés de processeurs graphiques pour effectuer des tâches d'apprentissage approfondies des données en un temps très court.

En 2016, le programme AlphaGo, mis au point par Google DeepMind, faisait sensation en battant au jeu de go, par le score de 4 à 1, le Sud-Coréen Lee Sedol, réputé le meilleur joueur du monde.

3.2 Définition de l'apprentissage profond

Avec l'apprentissage en profondeur, les modèles de calculs comportant plusieurs couches de traitement peuvent reconnaître la plupart des représentations de données à plusieurs niveaux d'abstraction.

Le Deep Learning est basé sur :

- Réseaux de neurones profonds
- Algorithme d'entraînement spécifique
- Apprentissage de représentations plus abstraites
- jeux de données plus grands

L'apprentissage en profondeur (Deep Learning) est un type d'apprentissage automatique (machine Learning) qui vise à former et à enseigner à l'ordinateur afin d'exercer des fonctions humaines telles que la distinction des objets visuels et l'identification des sons et des images. Au lieu d'organiser des données, l'apprentissage en profondeur définit ses propres paramètres de base, ce qui permet à la machine d'apprendre par elle-même, et l'intérêt actuel pour l'apprentissage en profondeur est en partie dû au bourdonnement qui entoure l'intelligence artificielle. Les techniques d'apprentissage en profondeur ont amélioré la capacité de classer, reconnaître, détecter, etc.

Deep Learning découvre la structure complexe dans de grands ensembles de données en utilisant l'algorithme de rétropropagation pour indiquer comment une machine doit modifier ses paramètres internes utilisés pour calculer la représentation de chaque couche à partir de la représentation de la couche précédente. Les réseaux convolutionnels profonds ont permis des avancées dans le traitement des images, de la vidéo, de la parole et de l'audio, tandis que les réseaux récurrents ont éclairé des données séquentielles telles que le texte et la parole.[10]

3.3 Fonctionnement de l'apprentissage profond

L'apprentissage en profondeur change votre façon de penser aux problèmes que vous résolvez avec l'analyse. Cela va de dire à l'ordinateur comment résoudre un problème, puis de le former à la résolution du problème lui-même.

Une approche classique de l'analyse consiste à utiliser les données disponibles pour concevoir des entités afin d'en déduire de nouvelles variables, puis sélectionner un modèle analytique et enfin estimer les paramètres (ou les inconnues) de ce modèle. Ces techniques peuvent donner des systèmes prédictifs qui ne se généralisent pas bien, car leur exhaustivité et leur exactitude dépendent de la qualité du modèle et de ses caractéristiques. L'ajout de plus de données nécessite de tout recommencer. La nouvelle approche basée sur l'apprentissage en profondeur consiste à remplacer la formulation et la spécification du modèle par des caractérisations hiérarchiques (ou couches) qui apprennent à reconnaître les caractéristiques latentes des données à partir des régularités des couches. Le changement de paradigme avec l'apprentissage en profondeur passe de l'ingénierie des fonctionnalités à la représentation des fonctionnalités.

Pour mieux comprendre comment le faire, prenons un exemple simple : nous voulons identifier un poisson parmi un grand groupe de poissons qui sont filmés, quelle que soit la manière dont ils sont photographiés.

À cette fin, une vaste collection d'images différentes de poissons et d'images d'autres objets doit être assemblée afin de former le réseau de neurones artificiels à la pratique de l'apprentissage en profondeur. Ces images sont converties en données et transmises au réseau après que le poids soit attribué à différents éléments par les cellules nerveuses artificielles. Les informations sont ensuite collectées par la dernière couche de neurones pour déterminer s'il s'agit d'un poisson ou non.

Ensuite, le réseau de neurones artificiels comparera ce résultat à la réponse fournie. S'il y a correspondance, le réseau enregistrera ce succès, car il l'utilisera dans d'autres communes. Si le résultat est négatif, le réseau reconnaîtra le déséquilibre et ajustera le poids des différents neurones pour corriger son erreur. Le processus se fait des milliers de fois jusqu'à ce que l'image soit reconnue et appelée ce type d'apprentissage par "apprentissage supervisé".

La seconde méthode est l'apprentissage non supervisé, qui repose sur des données non classifiées, c'est-à-dire que le réseau doit identifier des modèles dans les ensembles de données. Pour apprendre par eux-mêmes que tous les éléments de l'image peuvent être pertinents.

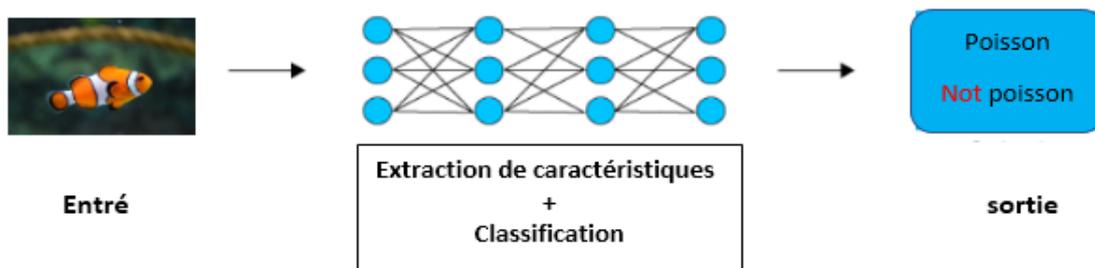


Figure II.5 : exemple de fonctionnement de Deep Learning

4 Domaine d'application de l'apprentissage

L'éducation en profondeur a été développée dans une large mesure, balayant les différents secteurs des TIC, par exemple, la reconnaissance visuelle du panneau de signalisation par un robot ou un véhicule indépendant et aussi la compréhension de l'image avec des réseaux convolutionnels profonds : Depuis le début des années 2000 <<ConvNet>> s'applique avec succès à la détection, à la segmentation et à la reconnaissance d'objets et de régions dans des images. De nouvelles classes de réseaux de neurones ont été développées et conviennent parfaitement à des applications telles que la traduction de texte et la classification d'images.

L'apprentissage en profondeur est apparu dans de nombreux autres domaines, notamment l'étude de l'ADN dans le domaine de la bio-informatique et dans celui de la santé en général en tant que diagnostic de certains cas médicaux, ainsi que dans le domaine de la sécurité informatique et non informatique. Il peut dessiner des tableaux de la même manière que le peintre apprit, et on le retrouve dans la science de l'éducation assistée par ordinateur et dans le domaine de l'intelligence artificielle en général.

Aujourd'hui, les entreprises utilisent de nombreuses applications pratiques du domaine de l'apprentissage en profondeur, notamment :

- **Reconnaissance de la parole** : Prenez, par exemple, Xbox, Skype, Google Now et Syrie d'Apple, qui utilise des techniques d'apprentissage approfondies dans leurs systèmes pour reconnaître les modèles de parole et les sons de l'homme.
- **Reconnaissance d'Image** : L'application pratique de la reconnaissance d'images est la traduction automatique d'images et la description de scènes. Cette application est très efficace dans le domaine des enquêtes pour déterminer l'activité criminelle parmi des milliers d'images fournies et les voitures peuvent en bénéficier grâce à l'identification d'images en utilisant la technologie de la caméra à 360 degrés.
- **Traitement du langage naturel** : Les réseaux de neurones constituent depuis de nombreuses années une composante essentielle de l'apprentissage en profondeur dans le traitement et l'analyse de textes écrits. Il peut également être utilisé pour découvrir et analyser les notes du médecin ou les reportages.
- **Systèmes de recommandation** : Amazon et Netflix ont tous deux intégré avec succès le concept du système de recommandation avec la possibilité de reconnaître votre degré d'intérêt la prochaine fois en fonction du comportement passé. Il est également utilisé dans d'autres domaines tels que la musique et d'autres domaines.

Dans le même temps, les interfaces homme-machine (IHM) ont beaucoup évolué. Y compris la souris et le clavier où ils ont été remplacés par des gestes ..., suscitant un regain d'intérêt pour l'IA et l'apprentissage en profondeur.

5 Architectures de réseaux de neurones profonds

Il existe un grand nombre de variables d'architectures profondes. Mais nous allons mentionner le plus important/standard.

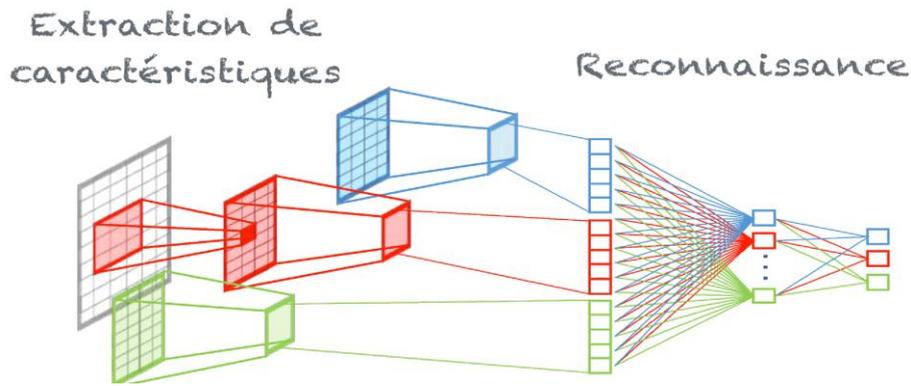


Figure II.6 : Architecture standard d'un réseau de neurones profond [78]

5.1 Les réseaux de neurones convolutifs (CNN)

Le réseau de neurones convolutifs (CNN) est un type de réseau de neurones artificiels, il est largement utilisé dans les applications graphiques telles que le traitement d'images et la reconnaissance vidéo, ainsi que dans les systèmes de recommandation. En particulier, il est largement utilisé dans le domaine de l'analyse d'images. CNN présente l'avantage d'utiliser des filtres de noyau (kernel) et mettent en œuvre du pooling.

5.1.1 L'opération de convolution

En mathématiques, un produit de convergence est à l'origine un produit alternatif et un opérateur binaire mélangé en même temps et dont le symbole est "*"

La représentation mathématique du concept de filtre linéaire est la généralisation de l'idée de régression moyenne par le produit de convolution, ce qui la rend valable pour toutes les données temporelles telles que le traitement du signal et les données spatiales dans le domaine du traitement d'images.

Le processus de convolution

Alors, quel est exactement le réseau de neurones de convolution ? Selon Chris Olah, chercheur scientifique chez Google Brain :

« À la base, les réseaux de neurones convolutionnels peuvent être considérés comme un type de réseau de neurones utilisant plusieurs copies identiques du même neurone. Cela permet au réseau de disposer d'un grand nombre de neurones et d'exprimer des modèles informatiques volumineux tout en conservant le nombre de paramètres réels (les valeurs décrivant le comportement des neurones) qui doivent être appris relativement petit. » [11]

Comme mentionné précédemment, la convolution est un outil mathématique très utile dans le domaine du traitement d'images, ce qui explique l'utilisation de réseaux de neurones à convolution dans le domaine de la prise de vue.

La convolution agit comme un filtrage. On définit une taille de fenêtre qui va se balader à travers toute l'image (rappelez-vous qu'une image peut être vue comme étant un tableau). Au tout début de la convolution, la fenêtre sera positionnée tout en haut à gauche de l'image puis elle va se décaler d'un certain nombre de cases (c'est ce que l'on appelle le pas) vers la droite et

lorsqu'elle arrivera au bout de l'image, elle se décalera d'un pas vers le bas, ainsi de suite jusqu'à ce que le filtre ait parcouru la totalité de l'image : [12]

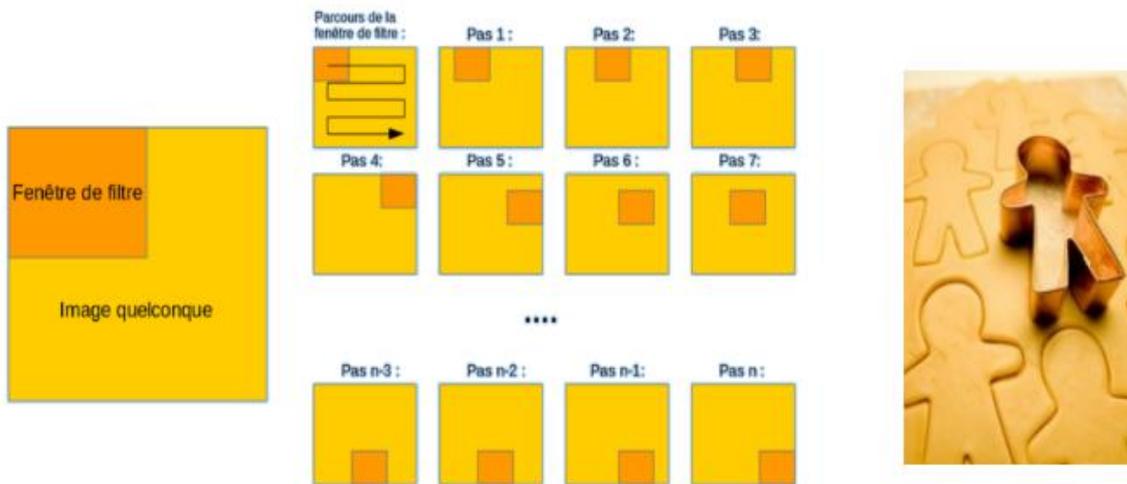


Figure II.7 : Schéma du parcours de la fenêtre de filtre sur l'image. [12]

Le but est de se servir des valeurs présentes dans le filtre à chaque pas. Par exemple si l'on définit une fenêtre 3 par 3, cela représentera 9 cases du tableau (c'est-à-dire 9 pixels). La convolution va effectuer une opération avec ces 9 pixels. Il peut s'agir de n'importe quelle opération, par exemple on extrait la valeur la plus grande (soit le pixel avec la plus grande valeur). [6]

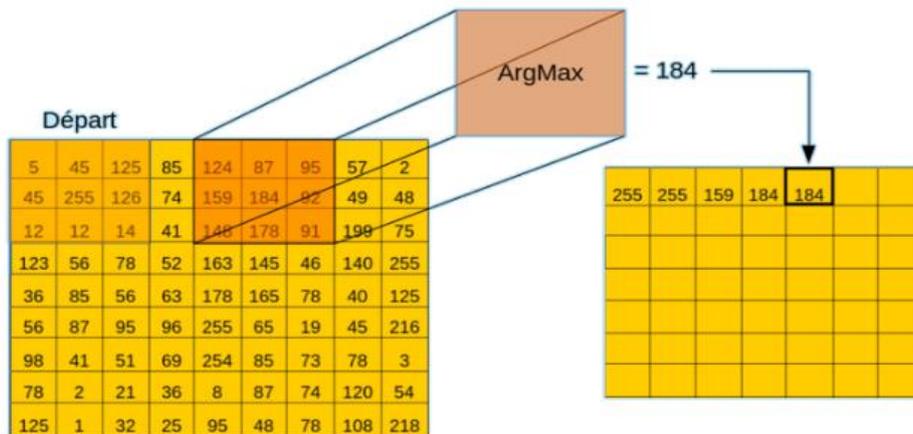


Figure II.8 : Exemple d'une convolution dont la configuration est : Opération = Argument maximal, pas horizontal = 1 pixel, pas vertical = 1 pixel. [12]

On fait glisser la fenêtre en orange et à chaque pas on récupère la valeur la plus grande parmi les 9 valeurs de pixels. [12]

La sortie de cette opération (convolution) qui s'appelle « carte de caractéristique » à des dimensions plus petites que celle de l'image en entrée

5.1.2 Les couches de CNN

La structure de CNN consiste en un ensemble de couches de traitement indépendantes :

- La couche de convolution (**CONV**) compétente pour traiter les données du champ du récepteur.
- La couche de pooling (**POOL**), qui a pour caractéristique de réduire sa taille, permettant la compression des informations, parfois par échantillonnage.
- La couche de correction (**ReLU**) est définie par son nom.
- Le coche "entièrement connecté" (**FC**), qui est une couche de type perception.
- La couche de perte (**LOSS**).

5.1.2.1 Couche convolution

Cette couche est le composant principal des réseaux de neurones convolutifs et constitue leur première couche. Sa fonction est de localiser un ensemble de caractéristiques(features) dans les images qui ont été données sous forme des entrées, raison pour laquelle nous effectuons un processus appelé méta-filtrage, dans lequel nous faisons glisser la fonction d'image dans une forme de fenêtre et calculons le produit de convolution entre la feature et chaque portion de l'image balayée. Ce processus produit une fonction d'image visualisée sous forme de filtre.

Pour mesurer le volume de la couche de convolution, nous avons besoin des trois hyperparamètres suivants :

1. **Profondeur de la couche** : Le nombre de noyaux de convolution ou le nombre de neurones qui ont une corrélation directe avec le même champ du récepteur
2. **Le pas** : Le pas contrôle le chevauchement des champs récepteurs. Plus le pas est petit, plus les champs récepteurs se chevauchent et plus le volume de sortie sera grand.
3. **La marge (à 0) ou zéro padding** : parfois, il est commode de mettre des zéros à la frontière du volume d'entrée. La taille de ce zéro-padding est le troisième hyperparamètre. Cette marge permet de contrôler la dimension spatiale du volume de sortie. [13]

5.1.2.2 Couche de pooling (POOL)

La chose la plus commune à propos de cette couche est qu'elle est placée entre deux couches de convolution, ce qui lui permet de recevoir de nombreuses feature maps en entrée, car elle s'applique à chaque processus de pooling.

L'opération de pooling (ou sub-sampling) consiste à minimiser la taille de l'image et à en préserver les propriétés importantes.

C'est pourquoi nous divisons l'image en cellules régulières, tout en conservant la valeur maximale dans chaque cellule. Les cellules utilisées sont carrées et petites pour éviter la perte de beaucoup d'informations. Les choix les plus communs sont des cellules adjacentes de taille 2×2 pixels qui ne se chevauchent pas, ou des cellules de taille 3×3 pixels, distantes les unes des autres d'un pas de 2 pixels (qui se chevauchent donc). On obtient en sortie le même nombre de feature maps qu'en entrée, mais celles-ci sont bien plus petites. La couche de pooling réduit le nombre de paramètres et de calculs dans la grille (réseau). [13] Ce qui augmente l'efficacité du réseau et limite le sur-apprentissage. Et donc de contrôler également le sur-ajustement. La couche de pooling fonctionne indépendamment sur chaque tranche de profondeur de l'entrée et la redimensionne spatialement, en utilisant l'opération MAX.

Donc la couche de pooling rend le réseau moins sensible à la position des features, qui est légèrement supérieure ou inférieure et peut présenter une tendance légèrement différente, mais ne doit pas entraîner de modification de la classification des images.

Parmi les caractéristiques connues de pooling est de donner une grande puissance de calcul, et malgré la très faible représentation (et donc la perte d'informations associées), toutes les tendances actuelles consistent à utiliser des filtres de petite taille (type 2×2). Mais le risque de sur-apprentissage posait de nombreux problèmes qui permettaient très bien d'éviter la couche de pooling

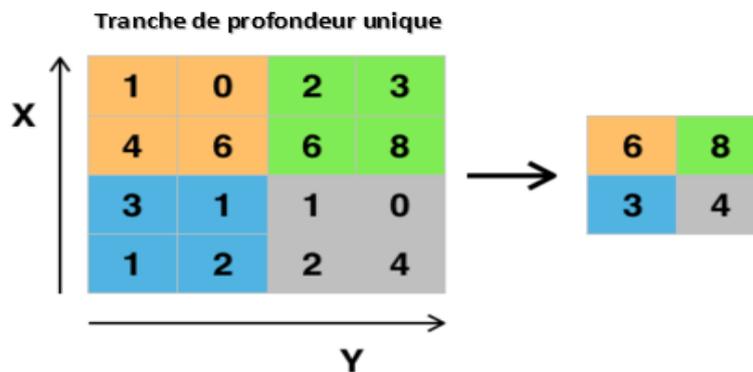


Figure II.9 : Pooling avec un filtre 2x2 et un pas de 2. [8]

5.1.2.3 Couche de correction (ReLU)

Pour améliorer l'efficacité du traitement en intercalant entre les couches de traitement une couche qui va opérer une fonction mathématique (fonction d'activation) sur les signaux de sortie. Dans ce cadre on trouve :

ReLU (Rectified Linear Units) désigne la fonction réelle non-linéaire, cette fonction, appelée aussi « fonction d'activation non saturante », augmente les propriétés non linéaires de la fonction de décision et de l'ensemble du réseau sans affecter les champs récepteurs de la couche de convolution définie par $\text{ReLU}(x) = \max(0, x)$.

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

- Souvent, la correction Relu est préférable, mais il existe d'autres formes
- La correction par **tangente hyperbolique** : $f(x) = \tanh(x)$,
- La correction par **la tangente hyperbolique saturante** : $f(x) = |\tanh(x)|$,
- La correction par **la fonction sigmoïde** : $(1 + e^{-x})^{-1}$. . [14]

5.1.2.4 Couche entièrement connectée

Après plusieurs couches de convolution et de max-pooling, il est nécessaire de penser haut niveau dans le réseau de neurones qui est formé de couches, ces dernières étant entièrement connectées. La couche entièrement connectée contient les neurones qui, à leur tour, contiennent des liens vers toutes les sorties de la couche précédente et sont gérés dans des réseaux de neurones réguliers, leur fonction d'activation pouvant être facilement calculée à l'aide d'une matrice de multiplication suivie d'une augmentation de la polarisation.

Ce type de couche reçoit un vecteur d'entrée et produit un nouveau vecteur de sortie. Pour cela, il applique une combinaison linéaire et éventuellement une fonction d'activation aux valeurs reçues en entrée.

5.1.2.5 Couche de perte (LOSS)

La couche de perte spécifie comment l'entraînement du réseau pénalise l'écart entre le signal prévu et réel. Elle est normalement la dernière couche dans le réseau. Diverses fonctions de perte adaptées à différentes tâches peuvent y être utilisées. La perte « Softmax » est utilisée pour prédire une seule classe parmi K classes mutuellement exclusives. [8]

5.1.3 Les paramètres de CNN

Les hyperparamètres sont l'utilisation la plus courante des réseaux de neurones, si on la compare au MLP standard. Il est nécessaire de prendre en compte les concepts les notions de nombre de filtres, leur forme et la forme du max pooling, bien que les règles habituelles pour les taux d'apprentissage et des constantes de régularisation soient toujours valables.

5.1.3.1 Nombre de filtres

En raison de la réduction de la taille des images intermédiaires en fonction de la profondeur du traitement, le nombre de filtres dans les calques proches de l'entrée est réduit, tandis que l'inverse se retrouve dans les calques les plus proches de la sortie où elles sont plus grandes. Cette couche est sélectionnée afin d'être presque constante sur toutes les couches. Il est très important de conserver le nombre de sorties intermédiaires (c'est-à-dire de multiplier le nombre d'images intermédiaires par le nombre de positions de pixels) afin de préserver les informations d'entrée. Afin d'augmenter (au sens large) d'une couche à l'autre. Le nombre d'images intermédiaires contrôle directement la puissance du système, dépend du nombre d'exemples disponibles et la complexité du traitement.

5.1.3.2 Forme du filtre

Les formes de filtrage sont souvent choisies en fonction de l'ensemble de données, en raison de la grande diversité de leurs formes dans la littérature. Les meilleurs résultats sont ceux obtenus sur MNIST (28×28) dans une plage de 5×5 dans la première couche, tandis que les images naturelles (souvent, avec des centaines de pixels dans chaque dimension) ont tendance à utiliser

des filtres de première classe 12×12 ou même 15×15 . Pour ce qui est de créer des abstractions dans la plage appropriée et de les adapter à chaque cas, nous devons trouver le niveau de granularité approprié pour cela

5.1.3.3 *Forme du Max Pooling*

Les valeurs typiques sont 2×2 . Des volumes d'entrée très importants peuvent justifier une mise en commun de 4×4 dans les couches inférieures. Cependant, le choix de formes plus grandes réduira considérablement la dimension du signal et peut entraîner une perte excessive d'informations. Souvent, les fenêtres de pooling ne se chevauchant pas donnent les meilleurs résultats.

5.1.4 Méthode de régularisation

Un des problèmes centraux de l'apprentissage automatique est de savoir comment créer un algorithme qui fonctionnera bien non seulement sur les données d'apprentissage, mais aussi sur les nouvelles entrées. De nombreuses stratégies utilisées dans l'apprentissage automatique sont explicitement conçues pour réduire l'erreur de test, éventuellement au détriment d'une erreur de sur-apprentissage. Ces stratégies sont connues collectivement comme régularisation. Un grand nombre de formes de régularisation sont à la disposition du praticien décourageant.

La régularisation est utilisée depuis des décennies avant l'apprentissage en profondeur.

5.1.4.1 *Empirique*

5.1.4.1.1 *Dropout*

La méthode du dropout consiste à « désactiver » des sorties de neurones aléatoirement (avec une probabilité prédéfinie, par exemple 0.5 pour les couches cachées et 0.8 pour la couche d'entrée) pendant la phase d'apprentissage. Cela revient à simuler un ensemble de modèles différents (bagging) et à les apprendre conjointement (bien qu'aucun ne soit appris de bout en bout). Pendant l'itération d'apprentissage, il est possible que tous les neurones soient inactifs, faire en sorte que chaque unité « bien apprendre » et cela indépendamment des autres et évite « co-adaptation », car le dropout peut entraîner un apprentissage accéléré.

La technique du dropout est notamment utilisée dans les systèmes de reconnaissance d'image, de voix, le classement de documents et sur des problèmes de calculs en biologie. [15]

5.1.4.1.2 *DropConnect*

Le DropConnect est une alternative au dropout consistant à inhiber une connexion (l'équivalent de la synapse), et ce de manière toujours aléatoire. Les résultats sont similaires (rapidité, capacité de généralisation de l'apprentissage) au dropout, mais présentent une différence au niveau de l'évolution des poids des connexions. Une couche « complètement connectée » avec un DropConnect peut s'apparenter à une couche à connexion « diffuse ». [16]

Lors de l'entraînement avec Dropout, un sous-ensemble d'activations sélectionné de manière aléatoire est mis à zéro dans chaque couche. Au lieu de cela, DropConnect définit à zéro un sous-ensemble de pondérations sélectionné de manière aléatoire dans le réseau. Chaque unité reçoit ainsi une entrée d'un sous-ensemble aléatoire d'unités de la couche précédente.

5.1.4.1.3 Pooling stochastique

Le même principe que nous trouvons au Max-pooling est également pris par le pooling stochastique, mais les sorties seront choisies de manière aléatoire en fonction de la distribution multinomiale qui est également déterminée en fonction de l'activité de la zone que le pool adressé. En fait, ce système est similaire à la création de Max-pooling avec un grand nombre d'images similaires, qui ne varient que par des déformations localisées. Cette méthode peut aussi être considérée comme une adaptation aux déformations élastiques de l'image.

C'est pourquoi cette méthode est très efficace sur les images MNIST (base de données d'images représentant des chiffres manuscrits). La force du pooling stochastique est de voir ses performances croître de manière exponentielle avec le nombre de couches du réseau.

5.1.4.2 Explicite

5.1.4.2.1 Taille du réseau

La convergence des traitements est l'un des problèmes les plus importants de ce que l'on appelle le sur-apprentissage, et la solution la plus simple consiste à réduire le nombre de couches du réseau et les paramètres libres (connexions) du réseau, ce qui réduit au moins directement le potentiel énergétique et prédictif du réseau. C'est équivalent à avoir une « norme zéro ».

5.1.4.2.2 Dégradation du poids

Une forme simple de régularisateur ajouté est la décroissance de poids, qui ajoute simplement une erreur supplémentaire, proportionnelle à la somme des poids (norme L1) ou de la magnitude au carré (norme L2) du vecteur de poids, à l'erreur à chaque nœud. Le niveau de complexité de modèle acceptable peut être réduit en augmentant la constante de proportionnalité, augmentant ainsi la pénalité pour les vecteurs de poids important.

- **La régularisation de L1** : La régularisation L1 conduit à la raréfaction des vecteurs de poids lors de l'optimisation. En d'autres termes, les neurones avec régularisation L1 n'utilisent qu'un petit sous-ensemble de leurs entrées les plus importantes et deviennent presque invariants par rapport aux entrées bruitées.
- **La régularisation L2** : La régularisation L2 interprète intuitivement les vecteurs de poids de pointe très pénalisants et privilégie les vecteurs de poids diffus. En raison des interactions multiplicatives entre pondérations et entrées, ceci a la propriété utile d'encourager le réseau à utiliser un peu toutes ses entrées, plutôt que certaines de ses entrées.

5.2 Les réseaux de neurones récurrents (RNN)

Au cours des années 90, de nombreux chercheurs se sont concentrés sur les réseaux de neurones récurrents, car ils constituaient une partie importante de la recherche sur les réseaux de neurones au cours de cette période et ont été appliqués à divers problèmes, notamment une séquence chronologique d'événements et les données ordonnées.

Les réseaux de neurones récurrents sont basés sur les travaux de David Rumelhart en 1986. La version la plus simple des RNN proposées par Jeff Elman en 1990 et dans laquelle on rajoute des liens à un MLP pour donner en entrée d'une couche du réseau sa propre sortie au pas de temps précédent en plus de la sortie courante de la couche précédente. En 1993, un système de

compression d'historique neuronal a résolu une tâche "d'apprentissage en profondeur" qui nécessitait plus de 1000 couches subséquentes dans un RNN déplié dans le temps.

5.2.1 C'est quoi un (RNN) ?

Un réseau de neurones récurrents (RNN) est une classe de réseaux de neurones artificiels où les connexions entre les nœuds forment un graphe dirigé le long d'une séquence. Cela lui permet de présenter un comportement dynamique temporel pour une séquence temporelle. Contrairement aux réseaux neuronaux à anticipation, les RNN peuvent utiliser leur état interne (mémoire) pour traiter des séquences d'entrées. Cela les rend applicables à des tâches telles que la reconnaissance de l'écriture manuscrite ou la reconnaissance vocale connectée, non segmentées.



Figure II.10 : Importance du contexte dans la reconnaissance de l'écriture manuscrite. Le mot « défense » est clairement lisible, mais la lettre « n » prise isolément est ambiguë.[17]

Le terme "réseau neuronal récurrent" est utilisé indifféremment pour désigner deux grandes classes de réseaux ayant une structure générale similaire, où l'une est impulsion finie et l'autre impulsion infinie. Les deux classes de réseaux présentent un comportement dynamique temporel. [18] Un réseau récurrent à impulsions finies est un graphe acyclique dirigé qui peut être déroulé et remplacé par un réseau neuronal strictement à anticipation, tandis qu'un réseau récurrent à impulsions infinies est un graphe cyclique dirigé qui ne peut pas être déroulé.

Les réseaux à impulsions finies et les réseaux récurrents à impulsions infinies peuvent avoir un état stocké supplémentaire et le stockage peut être sous le contrôle direct du réseau de neurones. Le stockage peut également être remplacé par un autre réseau ou graphique, s'il intègre des délais ou des boucles de retour. De tels états contrôlés sont appelés état bloqué ou mémoire bloquée et font partie de réseaux de mémoire à court terme (LSTM) et d'unités récurrentes déclenchées. [19]

Les RNN ont connu un grand succès dans les tâches d'étiquetage et de prédiction de séquences, tel que la reconnaissance de l'écriture manuscrite et la modélisation du langage. Dans la modélisation acoustique pour la reconnaissance de la parole, cependant, où les réseaux de neurones profonds (DNN) sont l'état de la technique établi, les RNN ont récemment reçu peu d'attention au-delà des tâches de reconnaissance téléphonique à petite échelle, les exceptions notables étant le travail de Robinson.

Un réseau de neurones récurrent et un réseau ConvNet fonctionnent ensemble pour reconnaître une image et en donner une description s'il n'y a pas de nom. Cette combinaison de réseau de neurones fonctionne de manière magnifique et produit des résultats fascinants. Voici une

description visuelle de la procédure. Le modèle combiné aligne même les mots générés avec les caractéristiques des images. [20]

5.2.2 Application RNN

Les réseaux de neurones récurrents jouent un rôle actif dans le domaine de la reconnaissance de la parole, tel qu'utilisé par Google Translation Network. Il a déjà été appliqué dans le domaine de la traduction automatique et de la commande de robot, ainsi que dans la prédiction de séries chronologiques. Il a réussi à l'apprentissage du rythme, la composition musicale et l'apprentissage grammatical, à détecter la parité des protéines et à prédire la sous-cellularisation cellulaire et la prévisibilité dans le secteur des soins médicaux, ainsi que de nombreuses tâches de prévision dans le domaine de la gestion des processus métiers, entre autres.

5.3 Apprentissage par renforcement

L'apprentissage par renforcement est un domaine de l'apprentissage automatique. Renforcement. Il s'agit de prendre des mesures appropriées pour maximiser les bénéfices dans une situation donnée. Il est utilisé par divers logiciels et machines pour trouver le meilleur comportement possible ou le meilleur chemin à suivre dans une situation donnée. L'apprentissage par renforcement diffère de l'apprentissage supervisé en ce sens que, dans l'apprentissage supervisé, les données de formation ont la clé de réponse ; le modèle est donc formé avec la bonne réponse alors que dans l'apprentissage par renforcement, il n'y a pas de réponse, mais l'agent de renforcement décide quoi faire. Pour effectuer la tâche donnée. En l'absence de jeu de données de formation, il est tenu d'apprendre de son expérience.

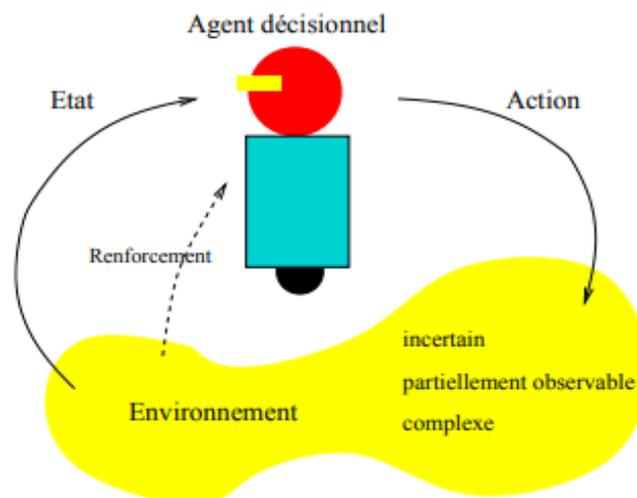


Figure II.11 : exemple d'un agent utilise l'apprentissage par renforcement

L'apprentissage par renforcement est souvent utilisé pour la robotique, les jeux et la navigation. Avec l'apprentissage par renforcement, l'algorithme découvre par essais et erreurs les actions qui génèrent les plus grandes récompenses. Ce type d'apprentissage comporte trois composantes principales : l'agent (l'apprenant ou le décideur), l'environnement (toutes les interactions avec l'agent) et les actions (ce que l'agent peut faire). L'objectif est que l'agent choisisse des actions

qui maximisent la récompense attendue sur une période donnée. L'agent atteindra son objectif beaucoup plus rapidement en suivant une bonne politique. L'apprentissage par renforcement vise donc à apprendre la meilleure politique.

6 Conclusion

Dans ce chapitre, nous avons parlé d'apprentissage automatisé et essayé de clarifier les concepts qui nous intéressent dans ce domaine, y compris la classification et les implications de la relation entre l'apprentissage automatique et l'apprentissage en profondeur. Nous avons mentionné comment nous avons évolué et comment nous avons évolué au cours de l'histoire et quels domaines d'application.

Nous ne nous sommes pas arrêtés à ce stade, car nous avons besoin des réseaux appelés réseaux de neurones (CNN), qui est spécialisé sur la classification d'image. Ces réseaux sont capables d'extraire des caractéristiques d'images présentées en entrée et de classer ces caractéristiques. Les réseaux de neurones convolutionnels présentent cependant un certain nombre de limitations, en premier lieu, les hyper paramètres du réseau sont difficiles à évaluer a priori. En effet, le nombre de couches, les nombres de neurones par couche ou encore les différentes connexions entre couches sont des éléments cruciaux et essentiellement déterminés par une bonne intuition ou par une succession de tests/calcul d'erreurs (ce qui est coûteux en temps).

Dans le chapitre suivant, on va parler sur la notion d'anapath et de prélèvements tissulaires ainsi que les outils de l'anatomopathologie et les techniques d'étude des tissus, puis nous avons consacré une partie pour les techniques de Deep Learning en général et plus précisément des réseaux de neurones convolutionnels pour le diagnostic pathologie (les lames anapathes).

CHAPITRE III

Les réseaux de neurones convolutionnels dans le domaine Médicale

1 Introduction

La pathologie numérique est un environnement d'information basé sur l'image, activé par la technologie informatique, qui permet la gestion de l'information générée à partir d'une diapositive numérique. La pathologie numérique est rendue possible en partie par la microscopie virtuelle, qui consiste à convertir des lames de verre en lames numériques pouvant être visualisées, gérées, partagées et analysées sur un écran d'ordinateur. Avec l'avènement de Whole-Slide Imaging, le domaine de la pathologie numérique a explosé et est actuellement considéré comme l'une des voies les plus prometteuses de la médecine diagnostique afin d'aboutir à des diagnostics, pronostics et des prédictions encore meilleures, plus rapides et moins coûteuses, du cancer et d'autres maladies importantes.

En pathologie, des anatomopathologistes formés examinent les lames de tissu au microscope. Le tissu sur ces lames est soumis à une coloration pour mettre en évidence les structures. Lorsque ces diapositives sont numérisées, elles peuvent alors être partagées (télépathologie) et analysées numériquement à l'aide d'algorithmes informatiques. Les algorithmes peuvent être utilisés pour automatiser le comptage manuel des structures ou pour classer l'état du tissu tel qu'il est utilisé dans le classement des tumeurs. Cela pourrait réduire les erreurs humaines et améliorer la précision des diagnostics. Les diapositives numériques sont également, par nature, plus faciles à partager que les diapositives physiques. Cela augmente le potentiel d'utilisation des données pour l'éducation et les consultations entre deux experts ou plus.

Dans ce chapitre nous allons donner quelques explications et définitions afin de donner un aperçu de la pathologie et décrire ci-dessous la relation d'apprentissage en profondeur dans le diagnostic de certains cancers et les techniques utilisées, lesquelles à leur tour dépendent des images prises à partir de l'anatomie. Ensuite, nous parlerons des techniques et méthodes adoptées et proposées pour le diagnostic, qui dépendent des images d'anatomie ou d'échantillons qui se présentent sous la forme d'images, et qui seront notre principale préoccupation concernant le diagnostic de certains types de cancers.

2 Définition d'anapath :

Selon « Dr.F. Bouldjenib » [21]

L'anatomie pathologique se définit comme « l'étude des lésions macroscopiques, histologiques, ultra structurale et bio moléculaire apportée par la maladie aux organes, aux tissus et aux cellules »

Le pathologiste, dans sa pratique quotidienne, est amené à analyser différents types de matériau cellulaire ou tissulaire, comme objectif constant de fournir :

- Un diagnostic lésionnel aussi précis que possible, en particulier concernant le type de la lésion.
- Toute information additionnelle ayant un impact sur :

- La prise en charge thérapeutique (grade, stade, expression de marqueurs moléculaires ...).
- Le diagnostic anatomo-pathologique découle d'une cascade d'étapes interdépendantes l'une de l'autre. Elles se résument en :
 - Étape du prélèvement
 - Étape de la fixation
 - Étape de la macroscopique
 - Étape de la confection des coupes histologiques :
 - Déshydratation
 - Désalcoolisation
 - Inclusion
 - Coupe
 - Étalement
 - Étape de la coloration et montage
 - Coloration
 - Montage
 - Étape de la lecture

La pathologie anatomique est elle-même divisée en sous-spécialités, les principales étant la pathologie chirurgicale : sein, gynécologie, endocrinienne, gastro-intestinale, tissus mous, tête et cou, dermatopathologie, la neuropathologie, l'hémato-pathologie, la cytopathologie et la médecine légale. [22]

L'approche anatomo-pathologique est basée sur la semi-analyse comparant des tissus naturels et pathologiques. Les organismes nuisibles sont confrontés à des données cliniques, biologiques et d'imagerie : des corrélations anatomiques sont nécessaires pour permettre une interprétation artificielle menant au diagnostic (spécifique, probable ou incertain).

Définition / général

- Composé de muqueuse, sous-muqueuse, musculieuse (propria) (externe) et séreuse (tissu périmusculaire dans le rectum)
- Mucosa : épithélium, lamina propria et musculieuse muqueuse
- Épithélium :
 - Cellules colonnaires à cuboïdes

- Les tubules sont étroitement emballés, ont une forme droite de tube à essai (ramification minimale), parallèle les uns aux autres, une surface liminale droite repose sur une mince membrane basale, s'étendent jusqu'à la musculaire muqueuse, avoir des cellules absorbantes et des cellules caliciformes
- Les cryptes s'ouvrent dans l'épithélium de surface ou dans les sillons innommés
- Les cryptes sont entourées d'une gaine de fibroblastes péricryptaux
- Les cryptes contiennent également des cellules précurseuses, des cellules endocrines et des cellules de Paneth dans le côlon droit
- La crypte intestinale est un compartiment prolifératif, monoclonal, maintenu par les cellules souches
- Villus représente le compartiment différencié et est polyclonal, car il reçoit des cellules de multiples cryptes.
- La signalisation Wnt est importante pour la prolifération cellulaire, la différenciation et l'apoptose le long de l'axe crypto-viliaire
- Les cellules Paneth constituent la niche des cellules souches Lgr5 dans les cryptes intestinales.
- Dans les cryptes du côlon, les cellules CD24 + résidant entre les cellules souches Lgr5 peuvent représenter les équivalents de cellules de Paneth
- Le cancer du côlon peut apparaître à la niche des cellules souches tissulaires (cellules souches du cancer) qui sont LGR5 +, Nanog-
- Taches positive : CDX2 (sensible et spécifique du colon), CK8, CK18, CK19
- Sillons innommés : zone muqueuse où plusieurs cryptes s'ouvrent dans une crypte centrale
- Lamina propria :
 - Capillaires (uniformes), lymphatiques juste au-dessus de la muqueuse musculaire
 - Cellules inflammatoires présentes (voir ci-dessous)
- Muscle de la muqueuse : mince et régulier
- Sous-muqueuse :
 - Tissu conjonctif lâche avec plexus sous-muqueux de Meissner
 - Infiltrat inflammatoire minimal
 - Les patients plus jeunes peuvent avoir des agrégats lymphoïdes intramucosaux qui perturbent la muqueuse musculaire

- Muscularis propria : couche circulaire interne, plexus myentérique d'Auerbach, couche longitudinale externe
- Serosa : couche unique de cellules mésothéliales cuboïdes plates à basses et de tissu fibroélastique adjacent

2.1 Lésion

On peut définir la lésion comme une altération morphologique ou bien une modification non physiologique, il peut trouver comme une conséquence de processus pathologique, macroscopique ou microscopique, d'une cellule, d'un tissu ou d'un organe....

Afin de bien discerner les lésions et les non-lésions, l'anatomopathologie nécessite une bonne maîtrise des notions de base d'anatomie, d'histologie et de physiologie : il est nécessaire de connaître le normal pour reconnaître l'anormal.[23]

2.2 La cytopathologie

La cytopathologie est une branche de la pathologie qui étudie et diagnostique des maladies au niveau cellulaire. Elle utilise des échantillons de cellules libres ou de fragments de tissus, contrairement à l'histopathologie, qui étudie des tissus entiers.

La cytopathologie est couramment utilisée pour enquêter sur des maladies impliquant un grand nombre de sites corporels, souvent pour faciliter le diagnostic du cancer, mais également pour le diagnostic de certaines maladies infectieuses et autres affections inflammatoires.

Les tests cytopathologiques sont parfois appelés tests de frottis, car les échantillons peuvent être étalés sur une lame de microscope en verre en vue d'une coloration ultérieure et d'un examen microscopique. [24]

Donc la cytologie est méthode d'analyse morphologique

- Elle se base sur l'étude des cellules
- Elle ne donne pas accès à la structure histologique
- Leur but est le diagnostic ou bien le dépistage

Pour les prélèvements cytologiques, ils peuvent être obtenus de différentes façons :

- Urine, expectoration, fistule, drain
- Raclage, brossage, aspiration de cellules desquamant spontanément
- Ponction à l'aiguille d'un liquide
- Ponction à l'aiguille d'un organe ou d'une tumeur
- Apposition d'un tissu (pièce opératoire, biopsie) sur une lame.

3 Prélèvements tissulaires

Ils sont réalisés selon trois modalités : la biopsie, les pièces opératoires et l'autopsie.

3.1 Biopsie

Une biopsie est un examen qui consiste à prélever un fragment de tissu ou d'organe, au moyen d'une aiguille ou par frottis. Le morceau retiré fait l'objet d'un examen microscopique et/ou d'une analyse biochimique pour déceler diverses anomalies ou maladies. La biopsie permet aussi d'évaluer la progression de la maladie si celle-ci est connue et de décider un traitement adapté. [25]

La biopsie nous permet également de suivre l'évolution de la maladie, de l'évaluer, de savoir si elle existe et de prendre les mesures nécessaires au traitement.

3.1.1 Pourquoi fait-on des biopsies ?

Les biopsies sont le plus souvent effectuées pour rechercher un cancer. Mais les biopsies peuvent aider à identifier de nombreuses autres conditions.

3.1.2 Types de biopsies

Il existe de nombreux types de biopsies :

- **Biopsie à l'aiguille** : La plupart des biopsies sont des biopsies à l'aiguille, ce qui signifie qu'une aiguille est utilisée pour accéder au tissu suspect.
- **Biopsie sous scanner** : Une personne repose dans un tomodynamomètre, les images du scanner aident les médecins à déterminer la position exacte de l'aiguille dans le tissu ciblé.
- **Biopsie guidée par échographie** : Un scanner à ultrasons aide un médecin à diriger l'aiguille dans la lésion.
- **Biopsie osseuse** : Une biopsie osseuse est utilisée pour rechercher un cancer des os. Cela peut être effectué par la technique du scanner ou par un chirurgien orthopédique.
- **Biopsie de la moelle osseuse** : Une grande aiguille est utilisée pour entrer dans l'os du bassin afin de recueillir la moelle osseuse. Ceci détecte les maladies du sang telles que la leucémie ou le lymphome.
- **Biopsie du foie** : Une aiguille est injectée dans le foie à travers la peau du ventre, capturant ainsi le tissu hépatique.
- **Biopsie rénale** : semblable à une biopsie du foie, une aiguille est injectée à travers la peau du dos, dans le rein.
- **Biopsie par aspiration** : Une aiguille retire du matériel d'une masse. Cette procédure simple est également appelée aspiration à l'aiguille fine.
- **Biopsie de la prostate** : Des biopsies à l'aiguille multiples sont prélevées à la fois de la prostate. Pour atteindre la prostate, une sonde est insérée dans le rectum.

- **Biopsie cutanée** : La biopsie est la principale méthode de diagnostic. Il utilise une lame circulaire pour obtenir un échantillon cylindrique de tissu cutané.
- **Biopsie chirurgicale** : Une intervention chirurgicale ouverte ou laparoscopique peut être nécessaire pour obtenir une biopsie des tissus difficiles à atteindre. Un morceau de tissu ou la totalité du tissu peut être retiré.

Un pathologiste examine le tissu de biopsie au microscope. En notant le type, la forme et l'activité interne des cellules du tissu, le pathologiste peut diagnostiquer le problème dans la plupart des cas.

Le temps nécessaire pour obtenir les résultats d'une biopsie peut varier. Pendant une intervention chirurgicale, un pathologiste peut lire une biopsie et en faire rapport au chirurgien dans quelques minutes. Les conclusions finales très précises sur les biopsies prennent souvent une semaine ou plus. Vous ferez probablement un suivi avec votre médecin traitant pour discuter des résultats de la biopsie.

Pour cette raison, cette science n'est pas restée l'apanage exclusif des médecins ou des spécialistes de ce domaine uniquement dans les cas où elle a été discutée et traités par tous en fonction de ses capacités et du grand développement de la science et de l'intelligence artificielle. Il est possible de diagnostiquer, identifier et catégoriser certaines maladies.

Les résultats des endoscopies intestinales avec cytologie au pinceau et biopsie de la même lésion au même moment pendant la période 1979-1984 ont été évalués afin de définir la valeur de ces méthodes. Les résultats ont été rapportés comme "cancer présent" ou "non présent" ou "suspect / prouvant" par rapport à "non suspect pour le cancer" et ont été analysés séparément. La biopsie s'est avérée plus sensible que la cytologie dans l'estomac et la cytologie plus sensible dans le côlon. La combinaison de la biopsie et de la cytologie a amélioré la sensibilité, en particulier dans l'œsophage, l'intestin grêle et le côlon, et peut aider à éviter les répétitions inutiles des évaluations endoscopiques. La spécificité s'est avérée extrêmement élevée lorsque les résultats ont été rapportés comme "cancer présent" ou "non présent", avec un seul rapport faux positif chez un patient atteint de colite ischémique. Dans plus de 60% des cas, le diagnostic final était un cancer si le rapport initial indiquait une suspicion de cancer, mais la spécificité de ces résultats était faible.

3.1.3 Quels sont les avantages et les risques de biopsie ?

- La biopsie à l'aiguille est une méthode fiable pour obtenir des échantillons de tissus permettant de déterminer si un nodule est bénin (non cancéreux) ou malin.
- La biopsie à l'aiguille est moins invasive que les biopsies chirurgicales ouvertes et fermées, qui impliquent toutes deux une incision plus importante dans la peau et une anesthésie locale ou générale.
- En règle générale, la procédure n'est pas douloureuse et les résultats sont aussi précis que lorsqu'un prélèvement de tissu est effectué chirurgicalement.

- Le temps de récupération est bref et les patients peuvent bientôt reprendre leurs activités habituelles.
- Toute procédure dans laquelle la peau est pénétrée comporte un risque d'infection. Le risque d'infection nécessitant un traitement antibiotique semble être inférieur à un sur 1000.

Généralement, une procédure de biopsie est sûre et ne cause que des blessures minimales. Les complications pouvant résulter des biopsies incluent :

- Saignement
- Infection
- Blessure accidentelle sur des structures adjacentes telles que l'intestin lors d'une biopsie abdominale ou un parenchyme pulmonaire lors d'une biopsie rénale

3.1.4 Quelles sont les limites des biopsies ?

Dans certains cas, la quantité de tissu obtenue à partir d'une biopsie à l'aiguille peut ne pas être suffisante et il peut être nécessaire de répéter la biopsie. Cela peut être particulièrement vrai lorsque vous essayez de diagnostiquer un lymphome.

Dans de rares cas, les procédures de biopsie mammaire moins invasives peuvent être incapables de détecter certaines lésions ou de déterminer l'étendue de la maladie présente. Si le diagnostic reste incertain après une intervention techniquement réussie, une biopsie chirurgicale sera généralement nécessaire.

Toute procédure guidée par imagerie ne pourra être utilisée que si la zone d'anomalie est visible. Certaines lésions, telles que les calcifications en grappes sur la mammographie, ne sont pas aussi clairement montrées en échographie qu'elles ne le sont en mammographie. Par conséquent, la biopsie stéréotaxique est généralement utilisée en imagerie du sein pour biopsie des calcifications. La fluoroscopie ne sera parfois pas en mesure de localiser les nodules thoraciques, et le scanner sera utilisé pour les conseils votre radiologue utilisera le guidage par image le mieux adaptée à la biopsie de la zone en question.

3.1.5 La valeur des biopsies

La valeur des biopsies repose sur :

1. leur taille (ex. : pour la recherche d'une artérite de Horton où les lésions sont segmentaires, une biopsie d'artère temporale représentative doit mesurer au moins 1,5 cm).
2. leur nombre : plus elles sont nombreuses, plus on a de chance de trouver du tissu tumoral, de rendre compte de l'hétérogénéité d'une tumeur et d'observer une lésion focale, mais importante pour le diagnostic.
3. le choix de la zone biopsie : éviter les zones nécrotiques ou hémorragiques ; sur la peau ou une muqueuse, éviter les prélèvements trop superficiels, biopsie le ganglion ayant fait l'objet d'une ponction cytologique motivant la biopsie.

4. la bonne préservation des tissus : ne pas étirer ou écraser les fragments, éviter le bistouri électrique « grillant » les tissus.
5. le repérage topographique de biopsies multiples (flacons différents répertoriés). [26]

4 Outils de l'anatomopathologie

Microscopes photoniques et électroniques, microtome, « tissus processor » (utilisé pour le traitement et la protection des tissus à analyser), ordinateur, tissus, organes, sécrétions, sang, sérum, etc.

4.1 Examen macroscopique

Quelle que soit l'évolution de la technologie et des appareils d'analyse, l'œil reste le principal outil des pathologistes. Avant tout, l'anatomie est considérée comme descriptive, en fonction du problème.

D'autres sens peuvent également être sollicités. Dans ce cas, le médecin décrira l'emplacement, la taille, la couleur, la forme, la consistance et la désignation de la tumeur, ses relations avec les autres organes, l'aspect de la coupure, etc. Lors d'un examen visuel, un médecin légiste peut utiliser une mesure pour évaluer les modifications possibles du poids de l'organe.

4.2 Examen microscopique

L'analyse microscopique est généralement l'activité principale du pathologiste. Il a pour cela recours aux outils de la microscopie, principalement optique ou photonique, mais également électronique. L'immunofluorescence, l'immunohistochimie et l'hybridation in situ sont également utilisées afin d'approfondir le diagnostic.

Cette étape permet d'affirmer le caractère tumoral ou non d'une lésion et le cas échéant d'aboutir à la dénomination de la tumeur, basée sur le type cellulaire d'origine. L'examen microscopique permet également d'apprécier les lésions de type inflammatoire et éventuellement d'identifier un agent causal (virus, bactéries, protozoaires, mycètes, parasites, etc.). [27]

L'histopathologie bénéficie grandement des analyses effectuées au microscope, à condition que l'échantillon soit pur et viable. Une culture, même si elle fournit une base solide, n'aide pas les scientifiques qui tentent de déterminer s'il y a eu ou non une invasion bactérienne ou une colonisation.

Dans ce cas particulier, une analyse au microscope est nécessaire pour qu'une histopathologie puisse établir un pronostic précis.

De plus, le microscope s'avère être l'un des outils les plus utilisés, et le plus fiables, des scientifiques qui étudient des agents pathogènes qui causent des modifications ou des dommages au tissu, car ils leur permettent de voir le niveau de dégradation des tissus et par conséquent de vérifier la progression des lésions. La maladie particulière.

L'analyse microscopique est importante en histopathologie, car elle permet aux scientifiques de visualiser les modifications tissulaires ou les signes d'infection, même en l'absence de l'agent pathogène.

Une histopathologie peut utiliser un microscope pour déterminer quel agent pathogène est responsable des dommages aux tissus en cas de présence de plusieurs agents infectieux, leur permettant ainsi de poser un diagnostic correct.



Figure III.1: Examen macroscopique d'une pièce opératoire.[26]

Mesure et dissection d'une pièce d'oesogastrectomie fixée dans le formol puis sélection des prélèvements destinés à l'étude.

Chaque lésion est repérée sur un schéma et éventuellement photographiée. Ces constatations sont confrontées aux documents cliniques et/ou radiologiques, ce qui souligne l'importance des renseignements écrits fournis par le médecin clinicien. En cas de pièces opératoires complexes (exérèse monobloc de plusieurs organes, ou pièce de résection selon une méthode non conventionnelle), le chirurgien devra adresser la pièce avec des indications de repérage topographique. Il peut être utile de marquer les berges d'une pièce de résection de tumeur avec une encre indélébile : ceci ne nuit pas à l'étude histologique et permet d'apprécier exactement la distance entre la tumeur et la limite chirurgicale de la pièce (figure 1.9). [26]

4.3 Les lames

L'anatomie pathologique numérique consiste à numériser une coupe histologique entière (qu'il s'agisse d'un seul prélèvement ou de plusieurs comme les tissue micro-arrays), afin de créer des lames virtuelles. Cette technologie est longtemps restée confidentielle ou jugée inappropriée, en raison de la mauvaise qualité des images engendrées et du temps mis pour les acquérir ; cependant, les progrès technologiques réalisés à ce jour sont tels que la qualité de la lame numérique est considérée actuellement comme équivalente à celle d'une lame observée au microscope classique.[28] [29] En outre, la microscopie virtuelle est souvent supérieure à la microscopie optique, notamment pour accélérer le processus de présélection de la section grâce aux observations correspondantes à faible et fort grossissement. De ce point de vue, nous

pouvons considérer les lames virtuelles comme une alternative possible aux lames traditionnelles.

Historiquement les racines de la pathologie numérique remontent aux années 1960, lorsque les premières expériences de télé pathologie ont eu lieu. Plus tard dans les années 1990, le principe de la microscopie virtuelle est apparu dans plusieurs domaines de recherche en sciences de la vie. Au tournant du siècle, la communauté scientifique s'accorda de plus en plus sur le terme « pathologie numérique » pour désigner les efforts de numérisation en pathologie. Cependant, en 2000, les exigences techniques (scanner, stockage, réseau) restaient un facteur limité pour une large diffusion des concepts de pathologie numérique.

Une diapositive virtuelle est créée lorsque des lames de verre sont numérisées dans leur intégralité afin de fournir une image numérique haute résolution à l'aide d'un système de numérisation numérique à des fins d'analyse d'images numériques médicales. Les diapositives numériques peuvent être récupérées à partir d'un système de stockage et visualisées sur un écran d'ordinateur en exécutant un logiciel de gestion d'images sur un navigateur Web standard et évaluées de la même manière que sur un microscope.

Les lames numériques ce sont des reproductions numériques d'une lame, obtenues par la juxtaposition de très nombreuses images, acquises automatiquement et successivement, à fort grossissement. Ces images numériques peuvent ensuite être facilement consultées par plusieurs pathologistes. C'est une technologie très utile pour l'enseignement, la relecture de cas lors de protocoles thérapeutiques ou en assurance qualité pour l'analyse de la reproductibilité diagnostique. [26]

La lame numérique permet l'analyse à distance, ce qui trouve tout son intérêt dans les régions particulièrement dépeuplées en pathologistes et/ou étendues géographiquement, le diagnostic pouvant concerner l'examen extemporané et/ou définitif. L'expérience du réseau de télé pathologie de l'Est-du-Québec (que décrivent Bernard Têtu et ses collaborateurs dans ce numéro. [29]

5 Techniques d'étude des tissus

La fixation, le traitement et la coloration sont des composants d'un processus utilisé pour capturer ou « fixer » des relations temporelles entre des cellules, et des composants cellulaires (par exemple des nucléoles) et extracellulaires (collagène dans la fibrose) d'un tissu. Par conséquent, lors de la première étape du traitement du tissu, le scientifique ou le pathologiste tente de stabiliser la micro-anatomie apparente du tissu (Arnold et al. 1996, Dapson et al. 2007, Eltoun et al. 2001, Fox et al. 1985) [Q5]. Bien que certains pensent que les produits visuels de la fixation, qui aboutissent à des coupes de paraffine de 4–5 μm , et la coloration immunohistochimique ou histochemique, représentent étroitement la micro-anatomie du tissu, chaque combinaison de fixation, de traitement et de coloration n'est que des compromis permettant la visualisation du résultat. Meilleure représentation statique d'un tissu vivant et dynamique (Grizzle, 2001). Le meilleur compromis pour la fixation et le traitement des tissus devrait également prendre en charge diverses autres méthodes d'étude de la micro-anatomie et de la microphysiologie, notamment l'analyse par coloration histochemique spéciale,

l'hybridation in situ, l'immunohistochimie et la microchimie, par exemple la spectrométrie de masse. Ainsi, le meilleur compromis pour la fixation et le traitement devrait minimiser les changements dans les tissus après leur élimination de l'organisme vivant tant dans la structure organisationnelle que dans la composition chimique (Grizzle 2001, Grizzle et al. 2007).

5.1 La fixation

La fixation des tissus est l'étape la plus cruciale dans la préparation des tissus pour l'observation au microscope électronique à transmission. La fixation comprend deux étapes : la cessation des fonctions vitales normales dans le tissu (destruction) et la stabilisation de la structure du tissu (préservation). Le but de la fixation est de préserver la structure le plus fidèlement possible par rapport à l'état vivant. Les trois paramètres les plus importants à retenir à propos de la fixation sont :

- (1) Réduire au minimum le délai entre la mise à mort et la fixation.
- (2) Gardez la taille du tissu aussi petite que possible sans perdre d'informations ni détruire le tissu. Si un échantillon de grande taille doit être fixé, conservez une dimension inférieure à 1 mm, sinon des zones de coupe de l'échantillon pouvant être jetées afin que le fixatif puisse pénétrer. La pénétration effective du fixateur est d'environ 0,5 mm pour l'osmium.
- (3) Minimiser la déformation des tissus en utilisant des instruments tranchants et en manipulant au minimum les échantillons.

Tout doit être mis en œuvre pour que le tissu reste humide dans un milieu physiologique jusqu'à ce qu'il soit en fixateur. La dissection dans un fixatif peut être utilisée si la manipulation de l'échantillon prend beaucoup de temps. Taille idéale du spécimen ou moins (taille réelle).

Si le spécimen flotte, il doit être immergé. Dans certains cas, cela peut être effectué en plongeant brièvement l'échantillon dans un agent mouillant avant la fixation ou en ajoutant un agent mouillant à la solution de fixateur. Si un agent mouillant est ajouté au fixateur, essayez de transférer le spécimen sur un nouveau fixateur dès que possible. L'air piégé étant souvent la cause de la présence de tissus dans le fixateur, l'air peut parfois être éliminé par aspiration partielle. Cependant, cela est parfois dommageable pour le spécimen. L'approche la plus douce consiste simplement à placer un bouchon de Kimwipe sous la surface du fixateur, ce qui emprisonnera l'échantillon sous la surface de la solution de fixateur.

Nature du fixateur : le fixateur le plus habituellement utilisé est le formol à 10 % tamponné. Pour les biopsies de petite taille, des fixateurs à base d'alcool peuvent être utilisés (fixation encore plus rapide, mais effet délétère sur certains antigènes, ce qui peut nuire à des techniques particulières d'immunohistochimie). Cas particuliers des tissus calcifiés : les prélèvements calcifiés (os, certaines tumeurs) doivent être sciés, puis fixés, puis plongés dans une solution décalcifiante (acide) avant d'être inclus dans la paraffine, ce qui rallonge la durée de la technique. [26]

5.2 Imprégnation et inclusion

La technique en paraffine est la méthode la plus couramment utilisée pour étudier la morphologie des tissus. Les protocoles d'imprégnation validés chez HISTALIM sont compatibles avec la plupart des méthodes de coloration ou de marquage. L'étape d'inclusion est faite dans le respect du standard RITA (Registry of Industrial Toxicology Animal-data). [30]

Les prélèvements ayant achevé leur fixation sont déposés dans des cassettes en plastique, directement s'il s'agit de biopsies ou s'il s'agit de pièces opératoires, après l'étape d'examen macroscopique au cours de laquelle sont prélevés des fragments de petite taille (en moyenne 2 x 0,3 cm). Puis les tissus contenus dans les cassettes sont déshydratés par passage dans des alcools, l'alcool est éliminé par des solvants (xylène), puis la paraffine liquide à 56 °C imprègne les tissus et est refroidie. Ces étapes sont automatisées dans des appareils à inclusion. L'étape finale de l'inclusion est manuelle et consiste à réorienter convenablement le fragment tissulaire dans le sens de la coupe dans un moule de paraffine (figure 1.10). [26]

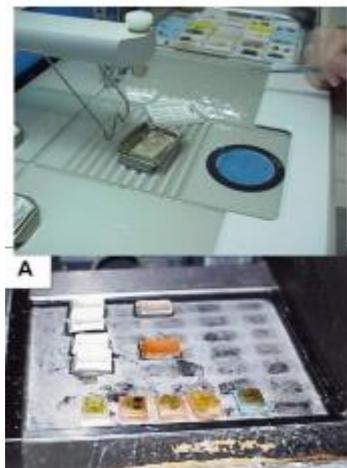


Figure III. 2: Inclusion manuelle du tissu dans un moule de paraffine.[26]

En haut : orientation des prélèvements dans la paraffine liquide. En bas : refroidissement de la paraffine.

5.3 Coupes et colorations

Le bloc solide de paraffine contenant le tissu est coupé grâce à un microtome, les coupes de 3 à 5 microns d'épaisseur sont étalées sur des lames (figure 1.11).



Figure III.3 : Technique histologique : étapes manuelles. [26]

B : coupe au microtome. C : étalement

Après dégradation de la paraffine, le processus de réhydratation est suivi d'une coloration des tissus. Cette coloration associe généralement le colorant nucléaire basique (hématoxyne, hématoxyline) et les colorants de l'acide cytoplasmique (éosine, érythrosine, ou phloxine). Dans la plupart des cas, le soi-disant safran, qui est associé au collagène, est ajouté (Fig. 1.12).

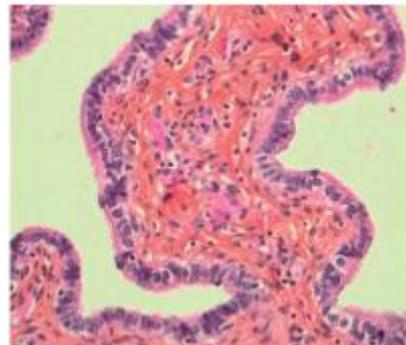


Figure III.3 : Coloration hématoxyline-éosine-safran d'une muqueuse de trompe utérine. [26]

Les cytoplasmes sont roses, les noyaux bleutés, le collagène jaune. La coupe colorée est protégée par une lamelle de verre collée, ou par un film plastique transparent (figure 1.13). Elle est alors prête à être analysée au microscope par un médecin anatomopathologiste.



Figure III.4 : Coupe du tissu étalé sur lame et coloré en hématoxyline-éosine-safran. [26]

En bas : tissu inclus en paraffine dans le bloc correspondant.

6 Les techniques de deep Learning pour le diagnostic pathologie

Depuis le début des années 1980, des systèmes de diagnostic assisté par ordinateur ont été introduits pour aider les médecins à interpréter les images médicales afin d'améliorer leur efficacité. Dans les systèmes de CAO avec imagerie médicale, les techniques d'apprentissage automatique sont largement utilisées pour la détection et le diagnostic du cancer. La plupart des modèles d'apprentissage en profondeur basés sur l'image ont été conçus sur la base de CNN, FCN, SSAE et DBN. Des études récentes montrent que les CNN réalisent des performances prometteuses dans la détection et le diagnostic du cancer

6.1 Autre réseau.

6.1.1 FCN

La principale différence entre les réseaux FCN et les réseaux CNN réside dans le fait que les réseaux FCN remplacent la couche entièrement connectée par une couche de suréchantillonnage et une couche de déconvolution. En outre, les réseaux FCN combinent les résultats des couches précédentes via les résultats de l'échantillonnage en élévation et de la déconvolution de la dernière couche (également appelée connexion par saut) afin d'améliorer encore la précision de la prédiction.

6.1.2 Encodeur automatique (AE)

Les auto-encodeurs (AE) appartiennent à un autre type de réseaux de neurones utilisés pour un apprentissage non supervisé [31]. L'objectif principal des AE est d'apprendre une représentation d'entité avec une dimensionnalité inférieure à partir des données d'entrée seules [32]. Un AE typique a une structure simple, qui comporte généralement trois couches : une couche d'entrée, une couche cachée et une couche de sortie. Les auto-encodeurs sparses (SAE) sont un type spécial d'AE dans lequel les unités cachées sont introduites en parcimonie en rendant le nombre de nœuds de la couche masquée supérieur à celui de la couche en entrée [32]. Un SSAE est une pile de SAE avec seulement une partie de codage et ils sont souvent formés de manière gourmande [32]. Il est capable d'apprendre la représentation des caractéristiques profondes à partir des données

6.1.3 Réseau de croyances profondes (DBN)

Deep Belief Network (DBN) est un modèle génératif probabiliste qui est construit par une pile de machines de Boltzmann restreintes (RBM) au lieu de AE (34). Un RBM a deux couches : **un calque visible et un calque caché.**

6.2 Les techniques CNN

Ces dernières années, de nombreux articles ont été publiés sur l'application de l'apprentissage en profondeur au dépistage et au diagnostic des maladies généralement et des cancers particulièrement.

6.2.1 Cancer du sein

Dans [33], Albayrak et al, a développé un algorithme d'extraction de caractéristiques basé sur l'apprentissage en profondeur pour détecter la mitose dans les images histopathologiques du sein. Dans l'algorithme proposé, le modèle CNN a été utilisé pour extraire les caractéristiques

utilisées pour former une machine à vecteurs de support (SVM) pour la détection de la mitose. AlexNet a construit un modèle CNN pour classifier les tumeurs bénignes ou malignes à partir d'images histopathologiques du sein [34]. Dans [35], Chen et al. a proposé un réseau en cascade profonde pour la détection de la mitose dans les lames d'histologie du sein. Dans [36], Xu et al, a proposé un algorithme basé sur un auto-codeur sparse (SSAE) pour classer les noyaux dans l'histopathologie du cancer du sein. En raison du manque d'images de formation pour former un modèle CNN profond, Suzuki et al, a développé une stratégie d'apprentissage par transfert pour former les modèles CNN à la détection de masse sur des images mammographiques [37]. Dans [38], Swiderski et al, a présenté un moyen de surmonter le sur-ajustement des modèles CNN lorsque les données de formation étaient limitées. Ils ont utilisé la factorisation matricielle non négative (NMF) et l'autosimilarité statistique pour enrichir les données d'apprentissage.

6.2.2 Cancer du poumon

L'apprentissage en profondeur a trouvé des applications dans la détection et le diagnostic du cancer du poumon et des recherches ont été menées sur différentes modalités d'image. Zhu et al, ont adopté des réseaux de neurones à convolution profonde (DCNN) pour prédire le temps de survie du patient directement à partir d'images pathologiques du cancer du poumon [39]. Hua et al, ont utilisé des techniques d'apprentissage en profondeur pour la classification des nodules pulmonaires dans des images tomodensitométriques 2D [40]. Ils ont formé deux modèles profonds de bout en bout, DBN et CNN, sur des images pulmonaires brutes. Hussein et al, a proposé un modèle CNN en profondeur à vues multiples, entraînaibles de bout en bout et formable, basé sur des images tomodensitométriques 3D pour la caractérisation des nodules [41]. Tajbakhsh et al, [42] ont étudié et comparé les performances de réseaux de neurones artificiels (RNA) et CNN artificiels à formation massive pour la détection et la distinction des nodules pulmonaires dans les images de tomodensitométrie. Deux méthodes de formation ont été utilisées dans la recherche : une formation avec des données limitées et une formation avec de grands ensembles de données. [43-46].

6.2.3 Cancer de la peau

Le cancer de la peau est un type de cancer commun et certains efforts fondés sur un apprentissage en profondeur ont été déployés pour développer des algorithmes permettant de diagnostiquer la maladie ces dernières années. Dans [47], Pomponiu et al, a proposé un algorithme pour la classification du cancer de la peau en utilisant un réseau CNN préformé, AlexNet, pour générer une représentation de haut niveau des échantillons de peau. Dans [48], Esteva et al, ont étudié les CNN préformés pour la classification du cancer de la peau et un grand ensemble de données (129 450 images cliniques) a été utilisé dans leur étude. Dans [49], Mahbod et al, étudié la classification des lésions cutanées à l'aide de CNN préalablement formé. Dans leur algorithme, une architecture préformée AlexNet et VGG16 [50] ont été adoptées pour extraire les traits profonds des images dermoscopiques pour la classification des lésions cutanées [49]. Dans [51], Massod et al, a proposé un modèle d'apprentissage semi-supervisé et auto-conseillé pour la détection du mélanome sur des images dermoscopiques. Dans [52], Demyanov et al, proposé d'utiliser des CNN profonds pour détecter deux types de motifs (réseau typique et globules réguliers) sur des images cutanées dermoscopiques. Dans la méthode proposée, le CNN a été formée à l'algorithme standard de descente de gradient stochastique.

6.2.4 Cancer de la prostate

Le cancer de la prostate a un taux de diagnostic élevé chez les hommes et constitue la troisième cause de décès chez les hommes [53]. Une segmentation réussie de la prostate est essentielle et difficile en radiothérapie pour le cancer de la prostate. La technologie d'apprentissage en profondeur a été utilisée pour la segmentation de la prostate. Dans [53], Guo et al, Apprentissage approfondi unifié avec appariement de patches clairsemés pour la segmentation de la prostate. Dans [90], Yan et al, proposé d'utiliser SAE comme classificateur pour détecter les régions du cancer de la prostate dans les images IRM. Outre le travail dans [48], Yan et al, a également proposé un autre modèle de segmentation de la prostate basé sur les caractéristiques extraites à l'aide d'une CNN [54]. Dans sa méthode, AlexNet a été adopté pour extraire des traits profonds d'un ensemble de propositions de prostate présélectionnées pour affiner les limites à une échelle plus fine. Milletari et al, ont formé CNN de bout en bout sur les volumes IRM pour la segmentation de la prostate [55]. Outre les images IRM et CT, des techniques d'apprentissage en profondeur ont également été adoptées pour détecter les cancers de la prostate à partir d'images pathologiques. Kwak et al, a proposé d'utiliser un modèle CNN profond pour la segmentation de la lumière et des cartes générées pour la classification des cancers de la prostate [56]. Källén et al, à proposer d'utiliser un modèle CNN basé sur les correctifs pour le classement de Gleason sur des images pathologiques [57]. Dans leur recherche, un modèle CNN préformé développé par OverFeat dans [58] a été adopté pour extraire les caractéristiques des patches d'image afin de former un classificateur.

6.2.5 Cancer du cerveau

La tumeur cérébrale est un désordre solide qui se développe de manière incontrôlée et peut se produire n'importe où dans le cerveau. Certaines recherches ont été menées sur les applications de l'apprentissage en profondeur pour la détection et le diagnostic du cancer du cerveau. Gao et al, étudie l'apprentissage en profondeur pour la classification des cellules tumorales dans les images cérébrales de tomodensitométrie [59]. Havaei et al, ont présenté un algorithme de segmentation de la tumeur cérébrale utilisant des modèles CNN pour les images IRM [60]. Les CNN proposées exploitaient à la fois des fonctionnalités locales et des fonctionnalités contextuelles globales et une dernière couche, une implémentation convolutionnels de la couche entièrement connectée, a été introduite dans l'architecture pour accélérer considérablement le processus. Zhao et al, a proposé une nouvelle méthode de segmentation de la tumeur cérébrale intégrant les FCN et les champs aléatoires conditionnels (CRFs) [61]. Dans [62], Paredes et al, a exploré l'impact potentiel de différents jeux de données d'images de formation sur les performances des CNN profonds.

6.2.6 Cancer colonic

Le cancer colorectal (CCR) est le troisième cancer en importance chez les hommes et les femmes. Afin d'aider les établissements médicaux à diagnostiquer le cancer colorectal, les chercheurs tentent d'utiliser des méthodes d'apprentissage en profondeur pour la détection des polypes du côlon. Ribeiro et al. Ont exploré les CNN pour la classification des polypes du côlon [63]. Navarro et al, ont également étudié les modèles CNN pour la classification des polypes du côlon. Ils ont comparé trois algorithmes différents basés sur des modèles CNN et un algorithme de base basé sur des fonctionnalités conçus à la main [64]. Yuana et al, a proposé

un algorithme basé sur CNN pour détecter automatiquement les polypes dans les vidéos de coloscopie [65]. Chowdhury et al, a proposé d'utiliser un modèle CNN pré-entraîné, AlexNet s'est formé sur la base de données ImageNet, en tant qu'extracteur de fonctions [66] pour la classification par grade du cancer du côlon.

Sirinukunwattana et al, ont proposé un réseau de neurones de convolution à contraintes spatiales (SC-CNN) pour la détection de noyaux dans des images histologiques de routine du cancer du côlon [67]. Dans l'algorithme, SC-CNN a d'abord été utilisé pour calculer la probabilité qu'un pixel soit le centre d'un noyau. Ensuite, un prédicteur d'ensemble voisin (NEP) couplé au CNN a été développé pour trouver le marqueur de classe des noyaux cellulaires détectés. Kashif et al, ont développé un nouveau modèle CNN appelé SC-CNN (CNN à contrainte spatiale) pour la détection de cellules tumorales dans des images histologiques [68]. Dans le modèle SC-CNN, deux couches ont été ajoutées dans le modèle CNN standard, qui visait à imposer des contraintes spatiales afin de le rendre non seulement capable d'extraire les caractéristiques de couleur, mais également d'extraire des informations de texture [68]. Dans [69], Xu et al, ont enquêté sur l'apprentissage en profondeur pour l'extraction automatique de caractéristiques. Ils ont étudié deux cadres d'apprentissage basés sur CNN (l'un s'appelait apprentissage supervisé complet et l'autre, apprentissage non supervisé) pour extraire des traits profonds à partir de blocs d'images pathologiques à des fins de classification [69]. Dans [70], Haj Hassan et al, a proposé d'utiliser les résultats de la segmentation par un modèle de contour actif pour former un modèle CNN pour la classification des tissus de CRC à partir d'images de biopsie multispectrale [70]

6.2.7 Autre type de cancer

Le cancer de la vessie a le taux de récurrence le plus élevé parmi tous les cancers. Le diagnostic et le cancer de la vessie pourraient être développés grâce à des méthodes d'apprentissage en profondeur. Cha et al, a proposé un algorithme basé sur CNN profond pour la segmentation de la vessie afin de faciliter la détection du cancer de la vessie en tomographie par scanner (CTU) [71]. Gordon et al, a proposé un algorithme utilisant des CNN avec des ensembles de niveaux pour segmenter la paroi de la vessie à partir de la région de la vessie interne et des structures à l'extérieur de la vessie [72]. Dans l'algorithme, un modèle CNN contenant deux couches de convolution, suivi d'une couche de regroupement, de deux couches de convolution connectées localement et d'une couche entièrement connectée.

Le nombre de cellules tumorales circulantes (CTC) dans le sang joue un rôle important dans le diagnostic précoce du cancer lorsque les tumeurs sont invisibles. Mao et al, a présenté un système basé sur CNN en profondeur pour la détection automatique de CTC basée sur une image. Dans le système proposé, une méthode d'apprentissage permettant de définir la limite de classification entre échantillons positifs et négatifs a été développée [73].

7 Conclusion

Le processus de dépistage cytologique dépend fortement de la connaissance du domaine des experts et prend beaucoup de temps et de main-d'œuvre. Ainsi, les méthodes assistées par ordinateur ont été étudiées. L'apprentissage en profondeur est l'une de ces méthodes assistées par ordinateur à l'étude.

Dans ce chapitre, nous avons essayé de clarifier le concept d'anapath (anatomie pathologie), et nous sommes allés un peu plus loin sur ce concept afin de comprendre comment le diagnostic est basé sur cette science, nous avons essayé de présenter certains des concepts figurant sous le titre de prélèvements tissulaires, ainsi que les outils de l'anatomopathologie. D'une certaine manière, nous avons mentionné certaines techniques d'apprentissage approfondi en diagnostic pathologique, qui ont été complétées et proposées par des chercheurs dans ce domaine, notamment pour détecter certains cancers à l'aide de CNN et d'autres méthodes d'apprentissage en profondeur. Don le chapitre suivant nous avons implémenter une petite application base sur le CNN pour la classification des lames pathologie.

CHAPITRE IV

Implémentation, résultat et évaluation

1 Introduction

Les techniques d'apprentissage automatique ont été largement utilisées dans la recherche en imagerie médicale sous la forme de nombreux algorithmes de classification et de classification réussis. De nombreux cliniciens connaissent bien l'efficacité des classificateurs, tels que la machine à vecteurs de support (SVM), et les algorithmes de classification, tels que le voisin k-plus proche (k-NN). L'apprentissage en profondeur (DL) a récemment fait son apparition en tant que méthodologie incontournable pour améliorer considérablement les performances des techniques d'apprentissage automatique existantes et pour résoudre des problèmes auparavant insolubles. En outre, DL est une méthodologie générique qui a également des effets perturbateurs dans d'autres domaines scientifiques. Il est donc devenu impératif pour les chercheurs en imagerie médicale d'adhérer pleinement à la technologie DL.

Dans ce chapitre, nous appliquerons l'un des types d'apprentissages en profondeur pour la classification des images pathologiques sous la forme de plusieurs tests sous différente architecture de modèle de CNN et de plusieurs types d'images à partir de base de données recueillies et prises à partir d'échantillons réels

2 Logiciels et bibliothèques utilisés

2.1 Python

Python est un langage de programmation interprété, multi-paradigme et multiplateformes. Il favorise la programmation impérative structurée, fonctionnelle et orientée objet. Il est doté d'un typage dynamique fort, d'une gestion automatique de la mémoire par ramasse-miettes et d'un système de gestion d'exceptions ; il est ainsi similaire à Perl, Ruby, Scheme, Small talk et Tcl.

Le langage Python est placé sous une licence libre proche de la licence BSD et fonctionne sur la plupart des plates-formes informatiques, des smartphones aux ordinateurs centraux, de Windows à Unix avec notamment GNU/Linux en passant par Mac OS, ou encore Android, iOS, et peut aussi être traduit en Java ou .NET. Il est conçu pour optimiser la productivité des programmeurs en offrant des outils de haut niveau et une syntaxe simple à utiliser. Il est également apprécié par certains pédagogues qui y trouvent un langage où la syntaxe, clairement séparée des mécanismes de bas niveau, permet une initiation aisée aux concepts de base de la programmation.

Python est un langage qui peut s'utiliser dans de nombreux contextes et s'adapter à tout type d'utilisation grâce à des bibliothèques spécialisées. Il est cependant particulièrement utilisé comme langage de script pour automatiser des tâches simples, mais fastidieuses, comme un script qui récupérerait la météo sur Internet ou qui s'intégrerait dans un logiciel de conception assistée par ordinateur afin d'automatiser certains enchaînements d'actions répétitives (voir la section Adoption). On l'utilise également comme langage de développement de prototype lorsqu'on a besoin d'une application fonctionnelle avant de l'optimiser avec un langage de plus bas niveau. Il est particulièrement répandu dans le monde scientifique, et possède de nombreuses bibliothèques optimisées destinées au calcul numérique. [1]

2.2 TensorFlow

TensorFlow est le deuxième Framework d'apprentissage automatique créé et utilisé par Google pour concevoir, élaborer et former des modèles d'apprentissage en profondeur. Vous pouvez utiliser la bibliothèque TensorFlow pour effectuer des calculs numériques, ce qui en soi ne semble pas très spécial, mais ces calculs sont effectués avec des graphiques de flux de données. Dans ces graphiques, les nœuds représentent des opérations mathématiques, tandis que les arêtes représentent les données, qui sont généralement des tableaux de données multidimensionnels ou des tenseurs, qui sont communiqués entre ces arêtes.

TensorFlow est la deuxième génération du système de Google Brain. La version 1.0.0 est sortie le 11 février 2017 alors que l'implémentation de référence tourne sur un seul appareil, TensorFlow peut être lancé sur plusieurs CPU et GPU (avec des extensions optionnelles telles que CUDA ou SYCL (en) pour GPGPU). TensorFlow est disponible en version 64-bits pour Linux, Mac OS, Windows et pour les plateformes mobiles sur Android et iOS. Son architecture flexible permet le développement sur plusieurs variétés de plateformes (CPU, GPU, TPU), allant du PC de bureaux à des clusters de serveurs et des mobiles aux dispositifs de bords. [2]

2.3 Keras

Keras a été initialement développé dans le cadre des travaux de recherche du projet ONEIROS (Système d'exploitation de robot intelligent neuroélectronique à extrémité ouverte).

Keras est une API de réseaux de neurones de haut niveau, écrite en Python, est une API conçue pour les êtres humains et non pour les machines. Keras applique les meilleures pratiques pour réduire la charge cognitive : il propose des API simples et cohérentes, il minimise le nombre d'actions utilisateur requises pour les cas d'utilisation courants et fournit un retour clair et exploitable en cas d'erreur. [2]

Cela rend Keras facile à apprendre et à utiliser. En tant qu'utilisateur de Keras, vous êtes plus productif. Cette facilité d'utilisation ne se fait pas au détriment de la flexibilité : car Keras s'intègre à des langages d'apprentissage approfondi de bas niveau (en particulier TensorFlow), il vous permet de mettre en œuvre tout ce que vous pourriez avoir construit. Dans la langue de base. En particulier, en tant que « tf.keras », l'API de Keras s'intègre de manière transparente à vos flux de travail TensorFlow. [2]

Les principales raisons d'utiliser Keras découlent de ses principes directeurs, principalement la convivialité. Au-delà de la facilité d'apprentissage et de création de modèles, Keras offre les avantages suivants : adoption étendue, prise en charge d'un large éventail d'options de déploiement en production, intégration à au moins cinq moteurs de traitement (TensorFlow, CNTK, Theano, MXNet et PlaidML), et un soutien important pour plusieurs GPU et une formation distribuée. De plus, Keras est soutenu par Google, Microsoft, Amazon, Apple, Nvidia, Uber et d'autres. [2]

2.4 Scikit-learn

Scikit-learn (anciennement scikits.learn) est une bibliothèque d'apprentissage automatique de logiciels libres pour le langage de programmation Python. Il présente divers algorithmes de classification, de régression et de regroupement, notamment des machines à vecteurs de support, des forêts aléatoires, l'amélioration du gradient, k-means et DBSCAN, et est conçu

pour interopérer avec les bibliothèques numériques et scientifiques Python NumPy et SciPy. [3]

Le projet Scikit-learn a débuté sous le nom de scikits.learn, un projet Google Summer of Code de David Cournapeau. Son nom provient de la notion qu'il s'agit d'un "SciKit" (SciPy Toolkit), une extension tierce développée et distribuée séparément à SciPy. Le code d'origine a été réécrit par la suite par d'autres développeurs. En 2010, Fabian Pedregosa, Gaël Varoquaux, Alexandre Gramfort et Vincent Michel, tous issus de l'Institut français de recherche en informatique et en automatisation de Rocquencourt, en France, a pris la direction du projet et a lancé le premier communiqué public le 1er février 2010. Du divers SciKit, Scikit-learn et SciKit-image ont été décrits comme "bien entretenus et populaires" en novembre 2012. Depuis 2018, Scikit-learn est en développement actif.[3]

2.5 ImageDataGenerator

Cette fonction génère des lots de données d'image de tenseurs avec une augmentation des données en temps réel. Les données seront bouclées (par lots). Keras possède cette classe ImageDataGenerator qui permet aux utilisateurs d'agrandir l'image à la volée très facilement.

Utilisé si votre statut d'utilisation n'est pas très courant et que vous ne disposez que de quelques photos dans votre jeu de données d'entraînement

3 Configuration utilisée dans l'implémentation

La configuration du matériel utilisé dans notre implémentation est :

- Un PC portable : DELL i3
- Carte graphique : Intel® HD Graphics 4000
- Processeur : Intel® Core™ i3-3217U CPU @ 1.80 GHz
- RAM de taille : 4.00 GO
- Disque dur de taille : ST500LT0 ST500LT012-1DG14 SCSI Disk Device
- Système d'exploitation : Windows 7 64 bits

4 Présentation de la base de données usuelle

Notre base de données c'est une collection des images pathologiques prises à partir d'échantillons réels des personnes infectées et non infectées (cancer de colon), ces images ont été traitées en laboratoire et à l'aide des lames virtuelles numérisées en images adaptées à la classification.

Notre base de données est divisée en deux types d'images :

- Type « 0 » : le cancer de côlon n'existe pas
- Type « 1 » : le cancer de côlon existe

Notre base compose de « 302 » images couleur, « 202 » images nous les avons rassemblés et « 100 » images nous avons été fournis par Département of Computer Science à l'Université

Warwick de Coventry, située à Coventry dans les Midlands de l'Ouest, à environ 150 kilomètres de Londres.[4]

Avec « 33 » images de classe 0 et « 269 » images de class 1. Dans cette base on trouve « 219 » images pour le train et « 83 » images pour le test.

- Class « 0 » :

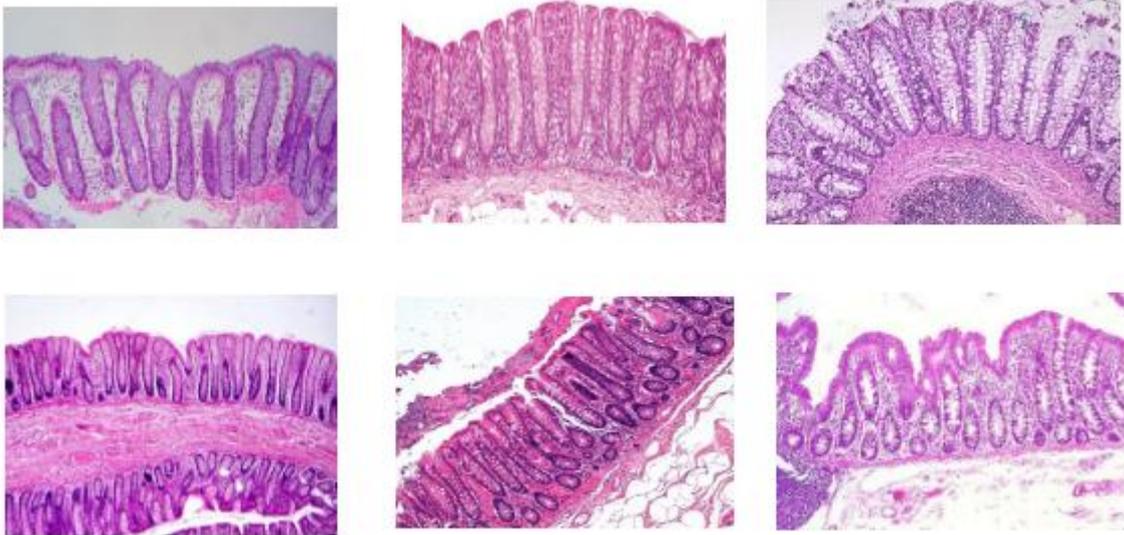


Figure IV.1 : image pathologie de class « 0 » (non infecter)

- Class « 1 » :

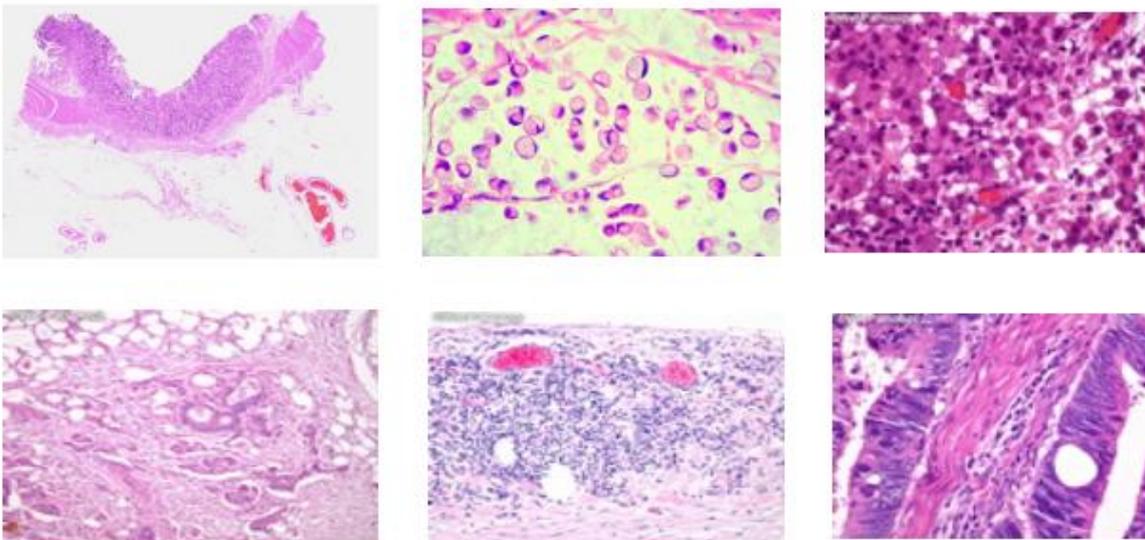


Figure IV.2 : images pathologie de class « 1 » (infecter)

Notre base est divisée en deux dossiers « train » et « test », et pour chaque dossier il existe les deux classes « 0 » et « 1 »

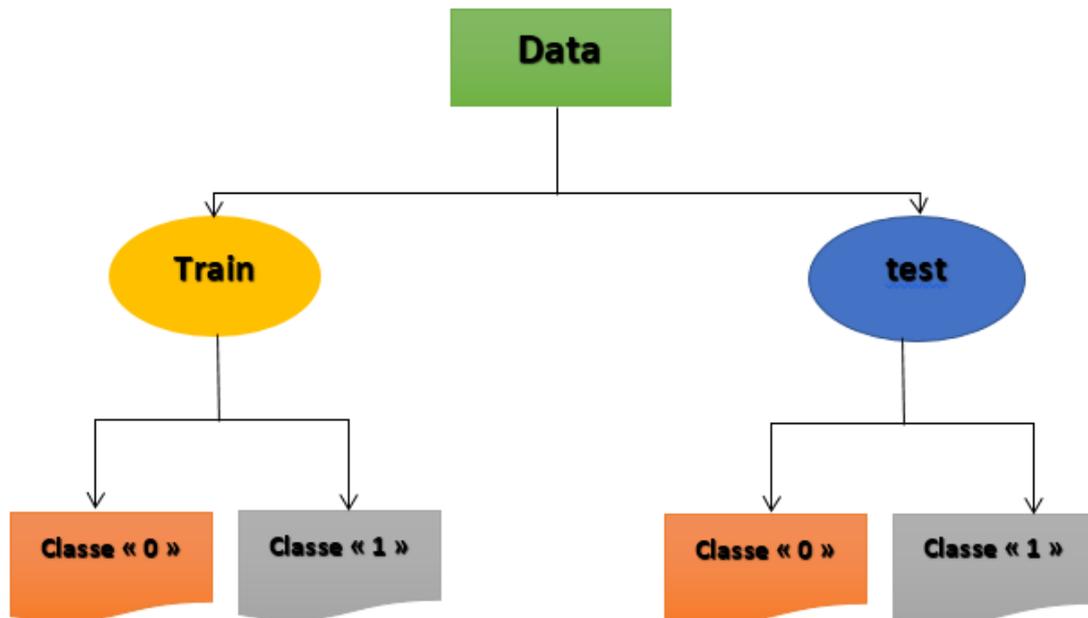


Figure IV.3 : La structure de base de données

Dans chaque classe les images sont de type « .jpg », et nommer d'une forme synchrone (1_0001, 1_0002 ...)

5 Conception de la méthode proposée

Dans notre proposition on a proposé un algorithme pour le binarisation d'image d'une façon classique et manuelle, et on a sauvegardé ces caractéristiques en quatre fichiers texte (des types de vecteurs), pour les utilisés aux plusieurs tests et aux plusieurs modèle de CNN.

Les fichiers sont les suivants :

- X_train.txt
- Y_train.txt
- X_test.txt
- Y_test.txt

5.1 Algorithmes propose

Algorithmes 1

Algo 1 pour le binarisation des photos sous forme des vecteurs enregistrés dans des fichiers texte.

Algo1

- **Import packages**
- Options pour les boutons
- Définir des boutons (Tkinter)
- Définir des options pour ouvrir ou sauvegarder un fichier
- Définir des options pour ouvrir un répertoire
- **Obtenir le nom du fichier ()**
- **Ouvrir le fichier ()**

'''retourne un fichier ouvert en mode écriture.

Cette fois, la boîte de dialogue retourne simplement un nom de fichier et le fichier est ouvert avec `'''` Votre propre code. `'''`

- **Obtenir le nom du fichier ()**
- **Ouvrir le fichier ()**
- **Renvoie un nom de répertoire sélectionné ()**
 - Initial_label
 - Initial_Data
- **Extraction des caractéristiques (List, pixel)**
 - **Convertir des images (mode, color, resize)**
- **Savetxt ('Y_test.txt', initial_label, fmt='%f')**
- **Savetxt ('X_test.txt', initial_label, fmt='%f')**

Fin

Algorithme 2

Algo 2 c'est pour la classification les images qui est binariser par **algo1**

Algo2**Import package**

```
'''Chargement des données'''
```

Début

Loading Data ()

- x_train= np.loadtxt ('X_train.txt', dtype=float)
- Y_train= np.loadtxt ('Y_train.txt', dtype=float)
- x_test= np.loadtxt ('X_test.txt', dtype=float)
- y_test= np.loadtxt ('Y_test.txt', dtype=float)

fin

declaration (weight_variable, bias_variable, conv2d, max_pool_2x2)

class DoubleGDOptimizer ()

input&output ()

```
'''CNN structure'''
```

Début

Model_CNN ()

train_model ()

Output (max_Accuracy)

Fin

Fin**Algorithmes 3**

Dans cet algorithme, nous allons utiliser les méthodes de bibliothèque « Keras », et la fonction « ImageDataGenerator » pour la base de données.

La classe ImageDataGenerator dispose de trois méthodes : flow (), flow_from_directory () et flow_from_dataframe (), leur rôle est de lire les images d'un grand vecteur NumPy et les différents dossiers qui contiennent ces images.

Pour la première étape on a téléchargé le jeu de données train et le jeu de données test, les extrayez dans 2 dossiers différents nommés « train » et « test ». Le dossier de train/test doit contenir « 2 » dossiers contenant chacune des images des 2 classes « saines » et « cancéreux ».

Algo3

Part 1

Début

- **Import package of Keras**
- **Initialisation du CNN ()**
- **Structure de CNN ()**
- **Compiler le CNN ()**

fine

Part 2

Debut

```
from keras.preprocessing.image import ImageDataGenerator
```

Adapter la CNN aux images

- **train_datagen = ImageDataGenerator** (rescale, shear_range, zoom_range, horizontal_flip)
- **test_datagen = ImageDataGenerator** (rescale)
- **training_set = train_datagen.flow_from_directory** ('train', target_size, batch_size, color_mode, class_mode)
- **training_set = train_datagen.flow_from_directory** ('test', target_size, batch_size, color_mode, class_mode)
- **model.fit_generator** (training_set, steps_per_epoch, epochs, validation_data = test_set, validation_steps)

Fin

- **Test_image_entrer** (image de test de model.jpg)

Fin**5.2 Méthode 1**

Dans cette méthode nous allons utiliser algo 1 pour l'initialisation de la base de données avec algo 2 pour construire notre modèle de CNN

5.2.1 Modèle 1

Ce modèle contient deux couches de convolution, chacune de nos couches de convolution est suivie par une fonction d'activation ReLU, $F(x) = \max(0, x)$ cette fonction force les neurones à retourner des valeurs positives.

Ensuite de cette fonction on applique le pooling pour réduire la taille de l'image ainsi la quantité de paramètres et de calcul. On parle dans ce cas-là de « Max-Pool 2x2 ». Après deux couches de convolution on a appliqué le Flatten puis on a proposé une couche full connected

Nous allons tester ce modèle à partir de plusieurs valeurs de paramètre

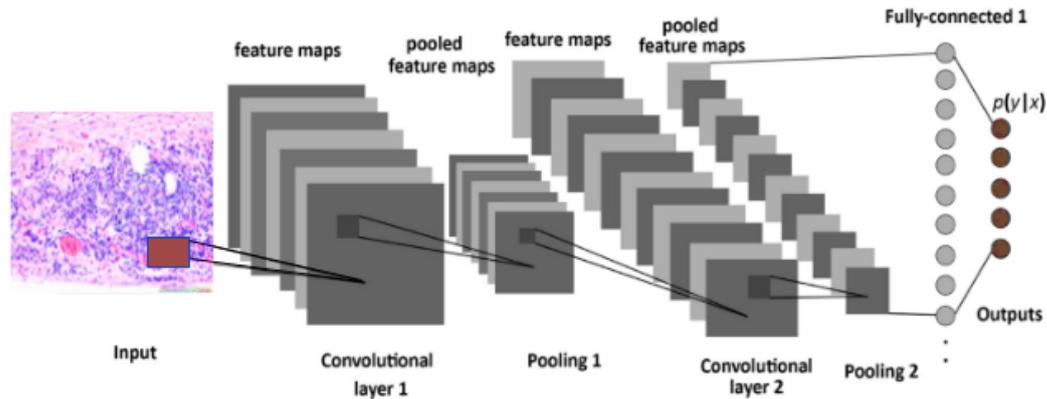


Figure IV.4 : architecture de modèle 1

Nous allons limiter le nombre de couches du réseau et libérer les paramètres libres (connexions) du réseau pour limiter le sur apprentissage. Ceci réduit directement la puissance et le potentiel prédictif du réseau.

Pour ce modèle nous avons fait plusieurs tests selon le type d'image (**RGB** et **GRAY**), et pour chaque test de type d'image nous avons fait des sous tests selon les sizes d'image.

5.2.2 Modèle 2

Dans le deuxième modèle nous allons changer l'architecture, nous allons ajouter une autre couche de convolution en changeant l'ordre des couches. Le modèle 2 présenté dans la (figure 4.5).

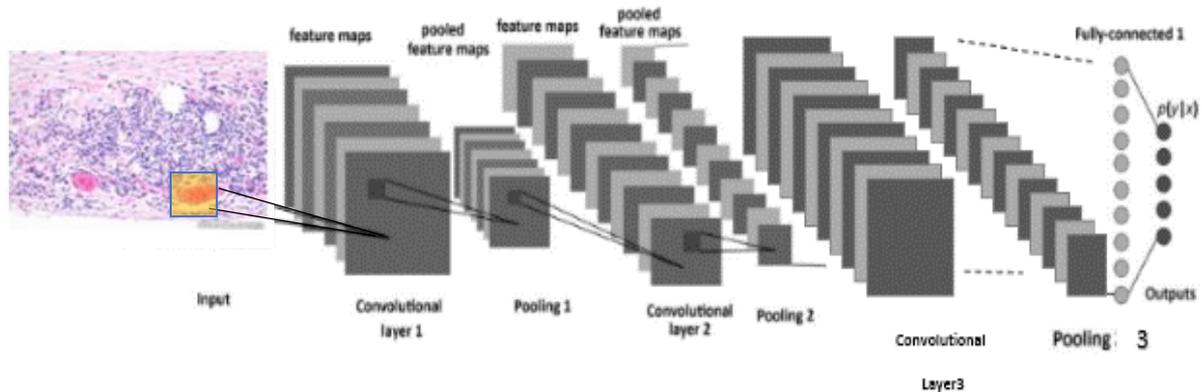


Figure IV.5 : architecture de modèle 2

Le Model est composé de trois couches de convolution et trois couches de Maxpooling et une seule couche de full connected

L'image en entrée est de certains taille, et de type spécifique, elle passe d'abord à la première couche de convolution. Cette couche est composée de kernel sise de taille 5*5, la fonction d'activation ReLU est utilisée, cette fonction d'activation force les neurones à retourner des valeurs positives, après cette fonction on a suivi par la deuxième couche de convolution qui est composée aussi de kernel sise de taille 5*5 avec un feature maps déférentes. La fonction d'activation ReLU est appliquée sur les couches de convolutions deuxième aussi. Le Maxpooling (2*2) est appliqué après pour réduire la taille de l'image et des paramètres. On a répété le mem structure pour la troisième couche de convolution avec les mêmes valeurs de kernel et les déférent feature maps.

Nous allons tester ce model avec les deux types d'image (RGB et GRAY), et avec les déférent size pour les deux types.

5.3 Méthode 2

Pour cette méthode nous allons utiliser algo 3 qui est base sur la bibliothèque de Keras, comme on a proposé pour cet algorithme deux modèles avec des architectures déférentes

5.3.1 Modèle 3

Notre modèle est composé de deux couches de convolutions, avec de filtre (32) et taille de kernel (3*3), chaque couche est liée par une fonction d'activation de type « ReLU », et suivi par une couche de pooling de type Maxpooling (2*2).

Après ces deux couches de convolution et de pooling nous allons littéralement aplatir notre carte de fonctionnalités regroupée dans une colonne avec la fonction « Flattening », on a terminé ce modèle avec une couche de « Full connection » qui est liée de fonction d'activation (sigmoid).

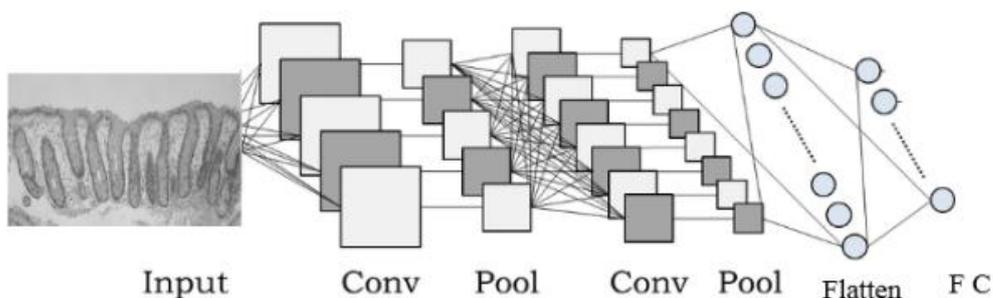


Figure IV.6 : architecture de modèle 3

Comme les précédents modèles de méthode 1, aussi nous allons fait des tests selon le mode (RGB et GRAY) et les tailles des images utiliser pour l'apprentissage.

Layer (type)	Output Shape	Param #
conv2d_1 (Conv2D)	(None, 62, 62, 32)	896
max_pooling2d_1 (MaxPooling2)	(None, 31, 31, 32)	0
conv2d_2 (Conv2D)	(None, 29, 29, 32)	9248
max_pooling2d_2 (MaxPooling2)	(None, 14, 14, 32)	0
flatten_1 (Flatten)	(None, 6272)	0
dense_1 (Dense)	(None, 128)	802944
dense_2 (Dense)	(None, 1)	129
Total params: 813,217		
Trainable params: 813,217		
Non-trainable params: 0		

Figure IV.7 : exemple table de configuration de test de mode RGB avec la taille 64*64 pour le modèle 3

Layer (type)	Output Shape	Param #
conv2d_1 (Conv2D)	(None, 62, 62, 32)	320
max_pooling2d_1 (MaxPooling2)	(None, 31, 31, 32)	0
conv2d_2 (Conv2D)	(None, 29, 29, 32)	9248
max_pooling2d_2 (MaxPooling2)	(None, 14, 14, 32)	0
flatten_1 (Flatten)	(None, 6272)	0
dense_1 (Dense)	(None, 2)	12546
Total params: 22,114		
Trainable params: 22,114		
Non-trainable params: 0		
None		

Figure IV.8 : exemple table de configuration de test de mode GRAY avec la taille 64*64 pour le modèle 3

5.3.2 Modèle 4

Ce modèle qui est présenté dans la **figure 4.9** est composé de trois couches de convolutions, chaque couche suivie par fonction d'activation de type ReLU et liée par de Maxpooling (2*2), puis on ajoute la fonction de Flattening, et ont déterminé avec la couche de Fully connected.

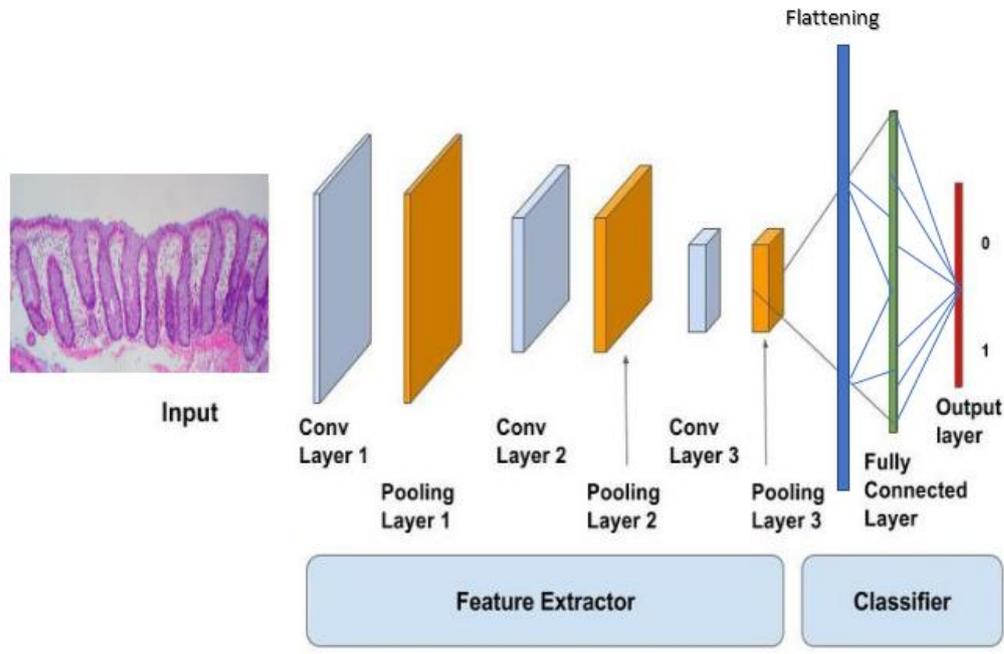


Figure IV.9 : architecture de modèle 4

Pour ce modèle nous allons appliquer plusieurs tests selon le mode d'image (RGB et GRAY) et aussi pour chaque mode on a fait plusieurs tests selon les tailles des images qui sont utilisées pour l'apprentissage.

Layer (type)	Output Shape	Param #
conv2d_1 (Conv2D)	(None, 62, 62, 32)	896
max_pooling2d_1 (MaxPooling2)	(None, 31, 31, 32)	0
conv2d_2 (Conv2D)	(None, 29, 29, 32)	9248
max_pooling2d_2 (MaxPooling2)	(None, 14, 14, 32)	0
conv2d_3 (Conv2D)	(None, 12, 12, 32)	9248
max_pooling2d_3 (MaxPooling2)	(None, 6, 6, 32)	0
flatten_1 (Flatten)	(None, 1152)	0
dense_1 (Dense)	(None, 128)	147584
dense_2 (Dense)	(None, 1)	129
Total params: 167,105		
Trainable params: 167,105		
Non-trainable params: 0		
None		

Figure IV.10 : exemple table de configuration de test de mode RGB avec la taille 64*64 pour le modèle 4

Layer (type)	Output Shape	Param #
conv2d_1 (Conv2D)	(None, 62, 62, 32)	320
max_pooling2d_1 (MaxPooling2)	(None, 31, 31, 32)	0
conv2d_2 (Conv2D)	(None, 29, 29, 32)	9248
max_pooling2d_2 (MaxPooling2)	(None, 14, 14, 32)	0
conv2d_3 (Conv2D)	(None, 12, 12, 32)	9248
max_pooling2d_3 (MaxPooling2)	(None, 6, 6, 32)	0
flatten_1 (Flatten)	(None, 1152)	0
dense_1 (Dense)	(None, 2)	2306
Total params: 21,122		
Trainable params: 21,122		
Non-trainable params: 0		
None		

Figure IV.11 : exemple table de configuration de test de mode GRAY avec la taille 64*64 pour le modèle 4

6 Expérimentation et résultats

Concernant l'algo 1, il est utilisé pour l'initialisation de base de donner avec déférent mode d'images et avec déférent taille. Il a donné des résultats qualifier pour les utilisés dans les modèles de CNN qui est défini par l'algo 2

6.1 Résultats de méthode 1.

Pour les premiers tests nous allons baser sur les paramètres de notre model 1 (deux couches de convolution)

Test de feat maps de modèle 1

<i>Méthode 1</i>	Feat_map 1	Feat_map 2	Acc
<i>Model 1</i>	2	4	0.86
	4	8	0.89
	6	12	0.86
	8	16	0.85
	9	18	0.86
	10	20	0.86
	8	6	0.87
	16	8	0.87

Table IV.1 : déférent résultats d'acc de modèle 1 pour déférent valeur de deux feat_map

Dans le premier test du premier modèle, nous avons essayé de travailler sur certaines variables qui ont une relation significative avec l'Accuracy (acc). Dans ce tableau, nous avons indiqué les valeurs les plus importantes pour le feat_map, qui donnaient des résultats différents. Nous avons également remarqué que je préférerais que le résultat se situe aux valeurs 4 pour le feat_map 1 et 8 pour le feat_map2, ce qui a donné le pourcentage le plus élevé du tableau (acc=0.89).

Test de feat maps de modèle 2

Dans cette partie du test, nous allons essayer de tester plus avant l'effet des valeurs de features maps sur l'Accuracy (acc) du deuxième modèle

<i>Méthode 2</i>	Feat_map 1	Feat_map 2	Feat_map 3	Acc
<i>Modèle 2</i>	2	4	8	0.84
	3	6	12	0.84
	4	8	16	0.84
	5	10	20	0.84

8	16	32	0.84
10	20	30	0.84
50	100	200	0.84

Table IV.2 : différent résultats d'acc de modèle 2 pour différent valeur de feat_map (1,2 et3)

À travers le tableau on constate que l'Accuracy est restée constante malgré le changement et la multiplicité des valeurs des trois features maps.

Après avoir comparé les deux tableaux précédents et les résultats obtenus, nous notons que les meilleures valeurs devant être poursuivies dans d'autres tests pour les deux modèles sont les suivantes :

Pour modèle 1

- Feat_map 1 = 4
- Feat_map 2 = 8

Pour modèle 2

- Feat_map 1 = 4
- Feat_map 2 = 8
- Feat_map 3 = 16

Test de GradientDescentOptimizer

Lors de notre prochain test, nous essaierons d'obtenir la meilleure valeur **GradientDescentOptimizer** pour les deux modèles.

GradientDescentOptimizer	Acc pour model 1	Acc pour model 2
0.001	0.84	0.84
0.002	0.89	0.84
0.003	0.89	0.84
0.004	0.89	0.84
0.005	0.87	0.84
0.006	0.87	0.84
0.007	0.87	0.84
0.008	0.87	0.84
0.009	0.87	0.84
0.01	0.86	0.84
0.02	0.84	0.84

0.03	0.85	0.84
0.04	0.85	0.84
0.05	0.85	0.84
0.06	0.85	0.84
0.07	0.84	0.84
0.08	0.84	0.84
0.09	0.84	0.84
0.1	0.84	0.84

Table IV.3: les résultats d'acc avec déferente valeur de GradientDescentOptimizer

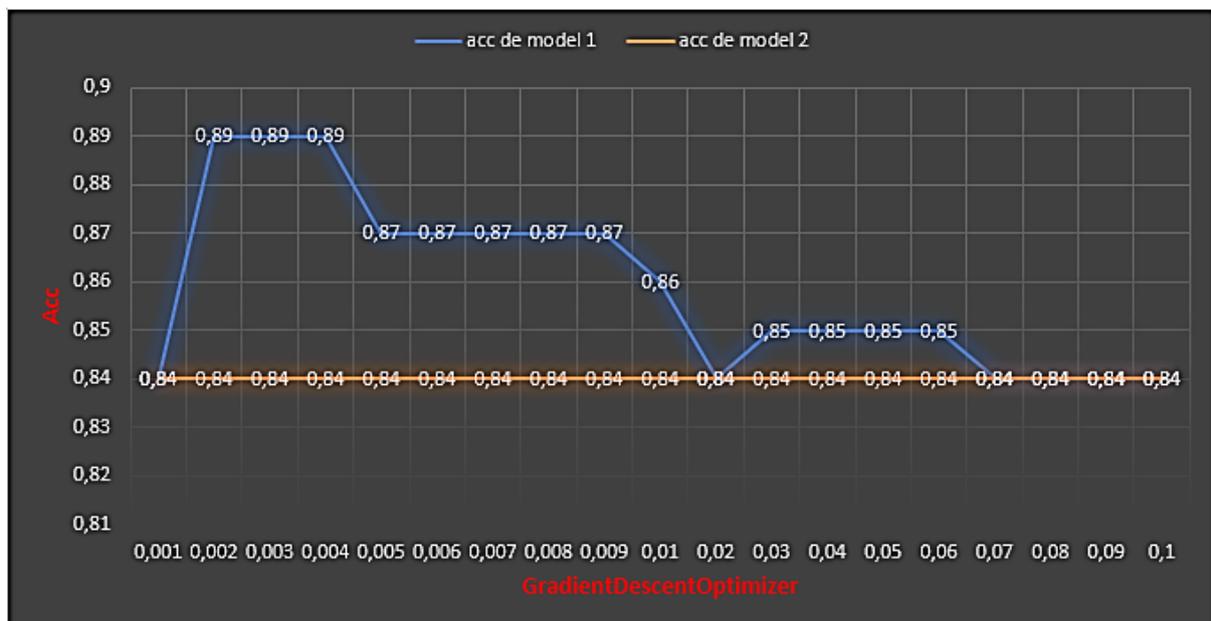


Figure IV.12 : les résultats d'acc avec déferente valeur de GradientDescentOptimizer pour modèle 1 et modèle 2

Il semble que cette variable n'a pas eu d'impact significatif sur le deuxième modèle, car l'Accuracy est restée constante et stable à 0,84 et n'a pas été affectée.

Quant au premier modèle, qui contient trois couches, la valeur la plus élevée était de 0,89, ce qui correspond à 0,002, 0,003 et 0,004 respectivement pour le **GradientDescentOptimizer**.

En raison de ce que nous avons obtenu précédemment, nous installerons la valeur GradientDescentOptimizer à 0,003 dans la suite des tests.

Taille	Mode	Acc pour model 1	Acc pour model 2
32*32	RGB	0.84	0.84
	GRAY	0.89	0.84
64*64	RGB	0.84	0.84
	GRAY	0.86	0.84
12*128	RGB	0.84	0.84
	GRAY	0.85	0.84

Table IV.4 : résultats de méthode 1 avec déférente taille et déférent mode d'image

Il semble que l'augmentation de la troisième couche de convolution n'a pas donné des nouveautés malgré tous les changements enregistrés au niveau des images utilisées dans le processus d'apprentissage, il n'y avait pas de changement par rapport au premier modèle, qui recevait la valeur la plus élevée d'Acc (0,89) lors du choix de la taille 32 * 32 de l'image grise qui est considéré comme la meilleure valeur enregistrée lors du choix d'images de couleur de toutes tailles.

Comme référence importante, nous constatons que la valeur d'Acc les plus élevés enregistrés lors du choix des images grises dans tous les cas.

Pour la suite nous allons comparons uniquement le premier modèle avec les tailles des images en mode grises.

Model	Mode	Taille	Acc
Modèle 1	GRAY	32*32	0.89
		64*64	0.86
		128*128	0.85

Table IV.5 : comparaison de résultats de modèle 1 en mode gris d'image

Nous notons que grâce aux résultats enregistrés dans ce tableau, la taille des images a un impact direct sur la proportion d'acc, car plus la taille est grande, plus la valeur d'acc diminue.

Pour la première méthode, la valeur la plus élevée a été enregistrée avec 0,89 d'acc dans le premier modèle qui contient deux couches de convolution, les images utilisées étaient de type gris et de taille 32 * 32, et semble avoir été la plus appropriée et la meilleure (valeur d'acc = 0.89).

6.2 Résultat de Méthode 2

Dans cette méthode qui est basée sur l'algorithme n ° 2, basé à son tour sur la bibliothèque Keras, nous poursuivrons les mêmes types de tests précédents pour voir comment chaque modèle réagi.

- **RGB**

	Modél 3		Modél 4	
Taille	Acc	Loss	Acc	Loss
32*32	0.94	0.14	0.95	0.14
64*64	0.97	0.07	0.94	0.15
128*128	0.98	0.03	0.96	0.10

Table IV.6 : les résultats de modèles 3 et 4 avec déférente taille en mode RGB

Pour le modèle 3, nous notons que la modification de la taille des images a un effet positif sur l'Accuraciy (acc). Plus les images sont grandes, plus l'Accuraciy est grande, contrairement à la valeur décroissante de la perte (loss).

La même chose s'est produite avec le modèle 4, mais si nous comparons les résultats des deux modèles, nous notons que le troisième modèle donne de meilleurs résultats que le quatrième, ce qui indique que deux couches de convolutions suffisent et que l'augmentation de la troisième couche diminue la valeur d'acc et n'améliore pas l'efficacité du modèle.

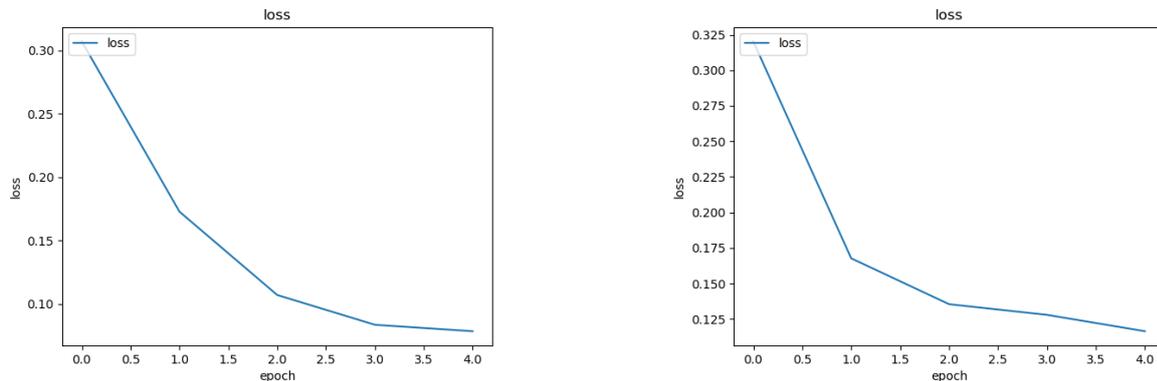


Figure IV.13: exemple de comparaison de valeur de loss entre les deux images de taille 64*64 Gris et RGB pour les deux modèles pour nbr epochs =5 (gauche le modèle 3 et a droit modèle 4)

- **GRAY**

	Modèle 3		Modèle 4	
Taille	Acc	Loss	Acc	Loss
32*32	0.94	0.16	0.94	0.18
64*64	0.95	0.11	0.95	0.12
128*128	0.96	0.07	0.97	0.07

Table IV.7 : les résultats de modèles 3 et 4 avec déférente taille en mode GRAY

Pour le deuxième test qui est basé sur l'utilisation d'images grises et des tailles différentes, on a remarqué que les résultats obtenus avec le même scénario du test précédent ont donné une grande Accuracy (acc) avec le quatrième modèle, qui contient trois couches de convolutions contrairement au troisième modèle.

Remarque : plus la taille des images utilisées lors de l'apprentissage est grande, plus l'Accuracy est grande, que ce soit l'image colorée ou grise.

Inévitablement, dans les tests précédents des deux modèles, il existe une relation inverse entre l'augmentation du nombre de couches de convolution et le type d'images utilisé, ce qui peut expliquer le fait que si nous utilisons des images en couleur, il ne faut que deux couches de convolution pour maintenir l'Accuracy, mais si nous utilisons des images en gris, il faut augmenter le nombre de couches afin d'obtenir une plus grande Accuracy.

6.3 Comparaisons des résultats de deux méthodes

Méthode1	Size	Mode	Top acc
Modèle 1	32*32-128*128	RGB	0.84
Model 2	32*32-128*128	RGB	0.84

Table IV.8 : les résultats de méthode 1 pour le mode RGB d'image

Méthode 2	Size	Mode	Top acc
Model 3	128*128	RGB	0.98
Model 4	128*128	RGB	0.96

Table IV.9 : les résultats de méthode 2 pour le mode RGB d'image

Méthode1	Size	Mode	Top acc
Model 1	32*32	GRAY	0.89
Model 2	32*32-128*128	GRAY	0.84

Table IV.10 : les résultats de méthode 1 pour le mode GRAY d'image

Méthode 2	Size	Mode	Top acc
Model 3	128*128	GRAY	0.96
Model 4	128*128	GRAY	0.97

Table IV.11 : les résultats de méthode 2 pour le mode GRAY d'image

Notez que dans les tableaux précédents, les deux Methods n'ont pas donné les mêmes résultats lorsqu'ils ont reçu la même entrée.

La première méthode donnait la plus grande Accuracy lorsqu'on utilisait des images grises et de petites tailles

Contrairement aux deuxièmes méthodes, qui contredit complètement et donne le meilleur résultat avec des images couleur et des images plus grandes.

En outre, nous notons que la plus grande Accuracy a été obtenue lors de l'utilisation de deux couches de convolutions uniquement dans les deux méthodes

NB : l'augmentation du nombre de couche de convolutions n'améliore pas l'Accuracy, car le nombre de photos que nous avons n'est pas assez grand.

7 Conclusion

Nous avons présenté dans ce chapitre une approche de classification basée sur les réseaux de neurones convolutionnels, pour cela nous avons utilisé différents algorithmes et des architectures différentes sous forme de deux méthodes et nous avons montré tous les résultats obtenus en termes d'exactitude et d'erreur. La comparaison des résultats trouvés était montrée que le type d'images, la taille, le nombre de couche et d'autres paramètres comme le feature maps et GradientDescentOptimizer.

Dans la plupart des tests, nous avons essayé de nous concentrer sur les images, car c'est la première source d'information pour nous et également parce qu'elle représente un élément sensible en raison de la possibilité d'existence ou non de maladie.

Nous avons tout mis en œuvre pour obtenir les résultats les plus précis et les plus élevés possible malgré la difficulté de les collecter, mais après plusieurs tests, nous avons obtenu de bons résultats et nous espérons pouvoir les utiliser pour le diagnostic du cancer du côlon à partir des lames numérotées.

Conclusion générale

La finalité de ce travail est de concevoir un système de détection automatique des anomalies dans une pièce anapath prélevée par une biopsie, frottis ou ponction. Pour ce faire on a montré en premier lieu l'intérêt de l'apprentissage profond et plus précisément les réseaux de neurones Convolutionnel pour la classification d'images.

Mais avant de réaliser cette tâche, nous avons dû passer beaucoup de temps sur la détection de concepts médicaux comme préliminaire. Ainsi nous nous sommes intéressés surtout aux techniques d'apprentissage profond pour y arriver, car ce sont les techniques les plus en vogue aujourd'hui.

Concernant la détection des concepts médicaux, nous avons transformé ce problème en un problème de classification. Nous avons collecté une quantité plus au moins importante des images captées par un microscope électronique pour des pièces du colon. Ou on a constaté que le nombre des pièces saines et beaucoup moins que les pièces malades, la chose qui a trop influencé sur nos résultats.

Pour améliorer ce résultat on a opté à bien comprendre les différentes couches utilisées dans la classification : la couche convolutionnels, la couche de rectification, la couche de pooling et la couche fully connected. Nous avons également parlé du problème de sur apprentissage et de la manière de le résoudre au moyen des méthodes de régularisation (dropout et data augmentation).

En phase d'application, on a compté sur le langage reconnu dans le domaine de deep Learning (PYTHON) avec les différentes bibliothèques dédiées à ce type de recherche tel que (TensorFlow, Keras...). On a commencé par une architecture de base (Convolutionnel -> rectification -> pooling) et on a essayé à chaque fois d'ajouter des couches éliminer d'autres en changeant au même temps les paramètres qui concerne la taille de la matrice de filtrage ainsi que la matrice de pooling jusqu'à l'obtention d'un taux de réussite important.

Pour terminer, la détection automatique de cancer à partir des lames anapath numérisé est une tâche très intéressante et présente un axe de recherche qui ne nécessite d'être développé parce qu'elle peut présenter de nombreux avantages si on la propose dans les institutions médicales surtout si on arrive à passer d'une tâche de classification binaire (existence de la tumeur ou non) à une phase qui permette de détecter le type et le stade du cancer.

Les perspectives à long terme sont d'essayer de détecter l'existence du cancer à partir d'une capture macroscopique afin de minimiser le nombre de traitements sur la pièce et aussi pour gagner le temps de diagnostique afin de lancer le traitement du patient le plutôt possible la chose qui va surement influencer sur le pronostic des pathologies oncologiques.

Référence

- [1] : <https://fr.wikipedia.org/wiki/Image>
- [2] : <https://www.supinfo.com/articles/single/2752-mieux-connaître-formats-image>
21/01/2019 à 19:45
- [3] : www.informatique-enseignant.com/image-bitmap-ou-vectorielle/ 23/01/2019 à 11:26
- [4] : <https://docplayer.fr/10786644-Republique...-d-informatique.html> 26/01/2019 à 23:45
- [5] : <http://yannicklufimpuluviya.e-monsite.com/pages/image-processing-theorie/chapitre-3-l-algorithme-de-mme-borgefors-comme-reduction-des-erreurs-dues-a-la-trame-carree/>29/01/2019 à 15:18
- [6] : https://www.memoireonline.com/12/09/3040/m_La-liaison-automatique-des-plusieurs-images- 02/02/2019 à 9 :23
- [7] : <https://towardsdatascience.com/automated-machine-learning-hyperparameter-tuning-in-python-dfda59b72f8a> , Will Koehrsen , Jul 3, 2018, /21/02/19
- [8] : https://fr.wikipedia.org/wiki/R%C3%A9seau_neuronal_convolutif/16/02/19
- [9] : <https://machinelearningmastery.com/gradient-descent-for-machine-learning/> 23/02/19
- [10] : REVIEW/ Deep learning/ Yann LeCun 1,2, Yoshua Bengio3 & Geoffrey Hinton4,5 / 28 MAY 2015 | VOL 521 | NATURE /doi:10.1038/nature14539/25/02/19
- [11] : <https://towardsdatascience.com/convolutional-neural-networks-the-biologically-inspired-model-f2d23a301f71> 28/02/19
- [12] : <http://www.natural-solutions.eu/blog/la-reconnaissance-dimage-avec-les-rseaux-de-neurones-convolutifs> /01/03/19
- [13] : <https://openclassrooms.com/fr/courses/4470531-classez-et-segmentez-des-donnees-visuelles/5083336-decouvrez-les-differentes-couches-dun-cnn> /03/03/19
- [14] : <https://www.datasciencetoday.net/index.php/fr/component/content/article?id=173:les-reseaux-de-neurones-convolutifs&Itemid=667> /05/03/19
- [15] : J. Goodfellow, Yoshua Bengio et Aaron Courville, Deep Learning, MIT Press, 2016 (ISBN 0262035618), chapitre 7./06/03/19
- [16] : Regularization of Neural Networks using DropConnect | ICML 2013 | JMLR W&CP 07/03/19
- [17] : Graves, A.; Liwicki, M.; Fernandez, S.; Bertolami, R.; Bunke, H.; Schmidhuber, J. (2009). "A Novel Connectionist System for Improved Unconstrained Handwriting Recognition" . IEEE Transactions on Pattern Analysis and Machine Intelligence. 31 (5): 855–868. CiteSeerX 10.1.1.139.4502. doi:10.1109/tpami.2008.137. PMID 19299860./08/03/19
- [18] : Miljanovic, Milos (Feb–Mar 2012). "Comparative analysis of Recurrent and Finite Impulse Response Neural Networks in Time Series Prediction" . Indian Journal of Computer and Engineering. 3 (1)./09/03/19

- [19] : https://en.wikipedia.org/wiki/Recurrent_neural_network /11/03/19
- [20] : <https://www.analyticsindiamag.com/overview-of-recurrent-neural-networks-and-their-applications/> 18/03/19
- [21] : laboratoire d'Anatomie et de Cytologie Pathologiques CHU de Constantine/ les bases élémentaires de L'Anatomie Pathologique/Dr F. Bouldjenib /2018_2019
- [22] : <https://fr.wikipedia.org/wiki/Anatomopathologie> 18/03/2019
- [23] : <http://www.chups.jussieu.fr/polys/anapath/Cours/POLY.Chp.1.html> 18/03/2019
- [24] : *Chapter 13, section of squamous cell carcinomas*, in Mitchell, Richard Sheppard; Kumar, Vinay; Abbas, Abul K.; Fausto, Nelson. Robbins Basic Pathology (8th ed.). Philadelphia: Saunders. ISBN 1-4160-2973-7.
- [25] : <https://www.passeportsante.net/fr/Maux/examens-medicaux-operations/Fiche.aspx?doc=examen-biopsie>
- [26] : Collège Français des Pathologistes (CoPath)/ Enseignement d'Anatomie pathologique POLYCOPIE/Moyens et objectifs de l'anatomie pathologique en médecine/Date de création du document 2011_2012
- [27] : <https://fr.wikipedia.org/wiki/Anatomopathologie>
- [28] : Bertheau P, Chabouis A, Fabiani B, *et al.* Télépathologie par lames virtuelles ou le diagnostic anatomopathologique en réseau numérique. Med Sci (Paris) 2012 ; 28 : 983–985. [CrossRef] [EDP Sciences][PubMed] [Google Scholar]
- [29] : Têtu B, Boulanger J, Houde C, *et al.* Le réseau de télépathologie de l'Est-du-Québec : un véritable projet collectif. Med Sci (Paris) 2012 ; 28 : 993–999. [CrossRef] [EDP Sciences] [PubMed] [Google Scholar]
- [30]: <https://www.histalim.com/fr/accueil/activites/nos-services/preparation-de-lames/> 21/03/19
- [31]: C.M. Bishop, Neural networks for pattern recognition, Oxford university press 1995.
- [32]: A. Ng, Sparse autoencoder, CS294A Lecture notes, 72 (2011) 1-19.
- [33]: A. Albayrak, G. Bilgin, Mitosis detection using convolutional neural network based features, Computational Intelligence and Informatics (CINTI), 2016 IEEE 17th International Symposium on, IEEE2016, pp. 000335- 000340.
- [34]: F.A. Spanhol, L.S. Oliveira, C. Petitjean, L. Heutte, Breast cancer histopathological image classification using convolutional neural networks, Neural Networks (IJCNN), 2016 International Joint Conference on, IEEE2016, pp. 2560-2567.
- [35]: H. Chen, Q. Dou, X. Wang, J. Qin, P.-A. Heng, Mitosis Detection in Breast Cancer Histology Images via Deep Cascaded Networks, AAAI2016, pp. 1160-1166.

- [36]: J. Xu, L. Xiang, R. Hang, J. Wu, Stacked Sparse Autoencoder (SSAE) based framework for nuclei patch classification on breast cancer histopathology, Biomedical Imaging (ISBI), 2014 IEEE 11th International Symposium on, IEEE2014, pp. 999-1002.
- [37]: S. Suzuki, X. Zhang, N. Homma, K. Ichiji, N. Sugita, Y. Kawasumi, T. Ishibashi, M. Yoshizawa, Mass detection using deep convolutional neural network for mammographic computer-aided diagnosis, Society of Instrument and Control Engineers of Japan (SICE), 2016 55th Annual Conference of the, IEEE2016, pp. 1382- 1386
- [38]: B. Swiderski, J. Kurek, S. Osowski, M. Kruk, W. Barhoumi, Deep learning and non-negative matrix factorization in recognition of mammograms, Eighth International Conference on Graphic and Image Processing, International Society for Optics and Photonics2017, pp. 102250B-102250B-102257.
- [39]: X. Zhu, J. Yao, J. Huang, Deep convolutional neural network for survival analysis with pathological images, Bioinformatics and Biomedicine (BIBM), 2016 IEEE International Conference on, IEEE2016, pp. 544-547.
- [40]: K.-L. Hua, C.-H. Hsu, S.C. Hidayati, W.-H. Cheng, Y.-J. Chen, Computer-aided classification of lung nodules on computed tomography images via deep learning technique, *OncoTargets and therapy*, 8 (2015).
- [41]: S. Hussein, R. Gillies, K. Cao, Q. Song, U. Bagci, TumorNet: Lung Nodule Characterization Using MultiView Convolutional Neural Network with Gaussian Process, arXiv preprint arXiv:1703.00645, (2017).
- [42]: N. Tajbakhsh, K. Suzuki, Comparing two classes of end-to-end machine-learning models in lung nodule detection and classification: MTANNs vs. CNNs, *Pattern Recognition*, 63 (2017) 476-486.
- [43]: B.-C. Kim, Y.S. Sung, H.-I. Suk, Deep feature learning for pulmonary nodule classification in a lung CT, Brain-Computer Interface (BCI), 2016 4th International Winter Conference on, IEEE2016, pp. 1-3.
- [44]: S.G. Armato, G. McLennan, L. Bidaut, M.F. McNitt-Gray, C.R. Meyer, A.P. Reeves, B. Zhao, D.R. Aberle, C.I. Henschke, E.A. Hoffman, The lung image database consortium (LIDC) and image database resource initiative (IDRI): a completed reference database of lung nodules on CT scans, *Medical physics*, 38 (2011) 915- 931.
- [45]: B. Van Ginneken, S.G. Armato, B. de Hoop, S. van Amelsvoort-van de Vorst, T. Duindam, M. Niemeijer, K. Murphy, A. Schilham, A. Retico, M.E. Fantacci, Comparing and combining algorithms for computer-aided detection of pulmonary nodules in computed tomography scans: the ANODE09 study, *Medical image analysis*, 14 (2010) 707-722.
- [46]: J.H. Pedersen, H. Ashraf, A. Dirksen, K. Bach, H. Hansen, P. Toennesen, H. Thorsen, J. Brodersen, B.G. Skov, M. Døssing, The Danish randomized lung cancer CT screening trial—overall design and results of the prevalence round, *Journal of Thoracic Oncology*, 4 (2009) 608-614.

- [47]: J. Shiraishi, S. Katsuragawa, J. Ikezoe, T. Matsumoto, T. Kobayashi, K.-i. Komatsu, M. Matsui, H. Fujita, Y. Kodera, K. Doi, Development of a digital image database for chest radiographs with and without a lung nodule: receiver operating characteristic analysis of radiologists' detection of pulmonary nodules, *American Journal of Roentgenology*, 174 (2000) 71-74.
- [48]: A. Esteva, B. Kuprel, R.A. Novoa, J. Ko, S.M. Swetter, H.M. Blau, S. Thrun, Dermatologist-level classification of skin cancer with deep neural networks, *Nature*, 542 (2017) 115-118.
- [49]: A. Mahbod, R. Ecker, I. Ellinger, Skin Lesion Classification Using Hybrid Deep Neural Networks, arXiv preprint arXiv:1702.08434, (2017).
- [50]: K. Simonyan, A. Zisserman, Very deep convolutional networks for large-scale image recognition, arXiv preprint arXiv:1409.1556, (2014).
- [51]: A. Masood, A. Al-Jumaily, K. Anam, Self-supervised learning model for skin cancer diagnosis, *Neural Engineering (NER)*, 2015 7th International IEEE/EMBS Conference on, IEEE2015, pp. 1012-1015.
- [52]: S. Demyanov, R. Chakravorty, M. Abedini, A. Halpern, R. Garnavi, Classification of dermoscopy patterns using deep convolutional neural networks, *Biomedical Imaging (ISBI)*, 2016 IEEE 13th International Symposium on, IEEE2016, pp. 364-368.
- [53]: Y. Guo, Y. Gao, D. Shen, Deformable MR prostate segmentation via deep feature learning and sparse patch matching, *IEEE transactions on medical imaging*, 35 (2016) 1077-1089.
- [54]: K. Yan, C. Li, X. Wang, A. Li, Y. Yuan, D. Feng, M. Khadra, J. Kim, Automatic prostate segmentation on MR images with deep network and graph model, *Engineering in Medicine and Biology Society (EMBC)*, 2016 IEEE 38th Annual International Conference of the, IEEE2016, pp. 635-638.
- [55]: F. Milletari, N. Navab, S.-A. Ahmadi, V-net: Fully convolutional neural networks for volumetric medical image segmentation, *3D Vision (3DV)*, 2016 Fourth International Conference on, IEEE2016, pp. 565-571.
- [56]: J.T. Kwak, S.M. Hewittb, Lumen-based Detection of Prostate Cancer via Convolutional Neural Networks, *SPIE Medical Imaging, International Society for Optics and Photonics2017*, pp. 1014008-1014008-1014006.
- [57]: H. Källén, J. Molin, A. Heyden, C. Lundström, K. Åström, Towards grading gleason score using generically trained deep convolutional neural networks, *Biomedical Imaging (ISBI)*, 2016 IEEE 13th International Symposium on, IEEE2016, pp. 1163-1167.
- [58]: P. Sermanet, D. Eigen, X. Zhang, M. Mathieu, R. Fergus, Y. LeCun, Overfeat: Integrated recognition, localization and detection using convolutional networks, arXiv preprint arXiv:1312.6229, (2013).
- [59]: X.W. Gao, R. Hui, Z. Tian, Classification of CT brain images based on deep learning networks, *Computer methods and programs in biomedicine*, 138 (2017) 49-56.

- [60]: M. Havaei, A. Davy, D. Warde-Farley, A. Biard, A. Courville, Y. Bengio, C. Pal, P.-M. Jodoin, H. Larochelle, Brain tumor segmentation with deep neural networks, *Medical image analysis*, 35 (2017) 18-31.
- [61]: X. Zhao, Y. Wu, G. Song, Z. Li, Y. Zhang, Y. Fan, A deep learning model integrating FCNNs and CRFs for brain tumor segmentation, *arXiv preprint arXiv:1702.04528*, (2017).
- [62]: D. Paredes, A. Saha, M.A. Mazurowski, Deep learning for segmentation of brain tumors: Can we train with images from different institutions?, *SPIE Medical Imaging, International Society for Optics and Photonics2017*, pp. 101341P-101341P-101346.
- [63]: E. Ribeiro, A. Uhl, M. Häfner, Colonic polyp classification with convolutional neural networks, *ComputerBased Medical Systems (CBMS), 2016 IEEE 29th International Symposium on, IEEE2016*, pp. 253-258.
- [64]: F. Navarro, Y. Saint-Hill-Febles, J. Renner, P. Klare, S. von Delius, N. Navab, D. Mateus, Computer assisted optical biopsy for colorectal polyps, *SPIE Medical Imaging, International Society for Optics and Photonics2017*, pp. 101340J-101340J-101347.
- [65]: Z. Yuana, M. IzadyYazdanabadia, D. Mokkaatib, R. Panvalkarb, J.Y. Shinc, N. Tajbakhshc, S. Gurudud, J. Liangc, Automatic polyp detection in colonoscopy videos, *SPIE Medical Imaging, International Society for Optics and Photonics2017*, pp. 101332K-101332K-101310.
- [66]: A. Chowdhury, C.J. Sevinsky, A. Santamaria-Pang, B. Yener, A computational study on convolutional feature combination strategies for grade classification in colon cancer using fluorescence microscopy data, *Proceedings of the SPIE, Volume 10140, id. 101400Q 5 pp.(2017). 140 (2017).*
- [67]: K. Sirinukunwattana, S.E.A. Raza, Y.-W. Tsang, D.R. Snead, I.A. Cree, N.M. Rajpoot, Locality sensitive deep learning for detection and classification of nuclei in routine colon cancer histology images, *IEEE transactions on medical imaging*, 35 (2016) 1196
- [68]: M.N. Kashif, S.E.A. Raza, K. Sirinukunwattana, M. Arif, N. Rajpoot, Handcrafted features with convolutional neural networks for detection of tumor cells in histology images, *Biomedical Imaging (ISBI), 2016 IEEE 13th International Symposium on, IEEE2016*, pp. 1029-1032
- [69]: Y. Xu, T. Mo, Q. Feng, P. Zhong, M. Lai, I. Eric, C. Chang, Deep learning of feature representation with multiple instance learning for medical image analysis, *Acoustics, Speech and Signal Processing (ICASSP), 2014 IEEE International Conference on, IEEE2014*, pp. 1626-1630.
- [70]: H. Haj-Hassan, A. Chaddad, Y. Harkouss, C. Desrosiers, M. Toews, C. Tanougast, Classifications of multispectral colorectal cancer tissues using convolution neural network, *Journal of pathology informatics*, 8 (2017).

[71]: K.H. Cha, L. Hadjiiski, R.K. Samala, H.P. Chan, E.M. Caoili, R.H. Cohan, Urinary bladder segmentation in CT urography using deep-learning convolutional neural network and level sets, *Medical physics*, 43 (2016) 1882- 1896.

[72]: M. Gordon, L. Hadjiiski, K. Cha, H.-P. Chan, R. Samala, R.H. Cohan, E.M. Caoili, Segmentation of inner and outer bladder wall using deep-learning convolutional neural networks in CT urography, *SPIE Medical Imaging, International Society for Optics and Photonics2017*, pp. 1013402-1013402-1013407.

[73]: Y. Mao, Z. Yin, J. Schober, A deep convolutional neural network trained on representative samples for circulating tumor cell detection, *Applications of Computer Vision (WACV), 2016 IEEE Winter Conference on, IEEE2016*, pp. 1-6.

Reference

[74]: [https://fr.wikipedia.org/wiki/Python_\(langage\)](https://fr.wikipedia.org/wiki/Python_(langage))

[75]: <https://keras.io/>

[76]: <https://en.wikipedia.org/wiki/Scikit-learn>

[77]: <https://warwick.ac.uk/fac/sci/dcs/research/tia/data/crchistolabelednuclei/> 12/06/2019

[78]: <https://www.senat.fr/rap/r16-464-1/r16-464-16.html>