

وزارة التعليم العالي والبحث العلمي
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique



جامعة عبد الحميد ابن باديس مستغانم
Université Abdelhamid Ibn Badis de Mostaganem

كلية العلوم والتكنولوجيا
Faculté des Sciences et de la Technologie



N° d'ordre : M2...../GE/2024

MÉMOIRE DE FIN D'ÉTUDES DE MASTER ACADEMIQUE

Filière : Électronique

Spécialité : Système Embarqué

Thème

Classification du cancer de la peau par l'intelligence artificielle.

Présenté par :

Mme BETTAHAR Fatima Zohra Mansouria

Mme BAGHDALI Imene

Soutenu le 24/06/2024 à 08h30 devant le jury composé de :

Président : Mr. BENAOUALI Mohamed	MAA	Université de Mostaganem
Examinatrice : Mme. BERRADJA Khadidja	MCA	Université de Mostaganem
Encadreur : Mme MEHIDI Aïcha	MCB	Université de Mostaganem
Co-Encadreur : Mme MIMI Malika	Professeur	Université de Mostaganem

Année Universitaire : 2023/2024

REMERCIEMENTS

Je tiens tout d'abord à remercier Dieu le tout puissant et miséricordieux, qui ma donnée la force et la patience d'accomplir ce modeste travail.

En second lieu, je tiens à remercier mon encadreur Mme MEHIDI Aïcha et mon Co-encadreur Mme MIMI Malika, pour ses précieux conseils et son aide durant toute la période du travail.

Mes vifs remerciements aux membres du jury Mr M. BENOUALI et Mme K. BERRADJA pour l'intérêt qu'ils ont accordé à ce modeste travail de recherche, et accepté aimablement de l'évaluer.

Enfin, je tiens également à remercier tous les enseignants qui ont contribué de manière notable à notre parcours universitaire.

Dédicace

Tout d'abord, j'exprime toute mon affection et mon respect aux personnes les plus chères de ma vie : ma sœur et mon frère qui m'a énormément manqué. À mon rayon de soleil, mon éclat de lune, ma chère maman, ma mamie Meriam, ma copine BAGHDALI Imene et mon petit chaton d'amour Lina. Un grand merci à Madame MEHIDI Aicha pour son aide précieuse. À toute la famille BETTAHAR et la famille FATTAH.

Mme. BETTAHAR Fatima Zohra Mansouria.

Dédicace

Je dédie ce mémoire à ma famille et à mes amis, dont le soutien inconditionnel m'a permis de surmonter tous les défis et d'atteindre cet accomplissement.

À mes parents, pour leur amour, leurs encouragements constants et leurs sacrifices inestimables, qui m'ont inspiré à poursuivre mes rêves et à persévérer dans mes études. À mon frère, ma sœur et son amie, mes cousins et ma copine BETTHAR Fatima Zohra Mansouria, pour leur présence et leur soutien précieux tout au long de ce parcours.

A tous ceux que j'aime et qui m'aiment.

Je tiens également à exprimer ma gratitude à mon encadreur et à mon co-encadreur pour leur guidance, leurs conseils avisés et leur soutien tout au long de ce travail.

Mme. BAGHDALI Imene.

Ces dernières années, l'apprentissage profond (deep learning) et plus particulièrement les réseaux de neurones à convolution (CNN) sont apparus spécialement pour résoudre les problèmes rencontrés dans l'intelligence artificielle. Le CNN est l'une des structures réseau les plus représentatives de la technologie d'apprentissage en profondeur (deep learning) et a connu un grand succès dans le domaine du traitement et de la reconnaissance d'images.

Dans le domaine de l'électronique médicale, la détection précoce de maladie, permet de limiter la propagation de la maladie ce qui revient à sauver des vies humaines. Pour cette raison, la médecine moderne nécessite de plus en plus de matériel électronique de nouvelle technologie. Ce dernier a besoin d'une maintenance et des mises à jour technologiques assurées par des spécialistes en électronique médicales et en traitement d'images.

Le diagnostic assisté par ordinateur du cancer de la peau devient de plus en plus une nécessité étant donné la croissance exponentielle des images à expertiser chaque année. Différents travaux de recherche ont été menés soit pour détecter automatiquement les lésions dans les images à l'aide des systèmes de détection assistée par ordinateur soit pour fournir un second avis à propos de la lésion détectée à travers des systèmes de diagnostic assisté par ordinateur. L'objectif principal de cette recherche est de mettre au point un système d'aide automatique pour bien classifier différentes pathologies du cancer de la peau en deux catégories, à savoir bénignes et malignes.

Mots Clés : L'intelligence artificielle, apprentissage automatique, deep learning, classification, cancers de la peau; prétraitement, CNN, ResNet18, VGG16.

ABSTRACT

In recent years, deep learning and more particularly convolution neural networks (CNN) have appeared especially to solve the problems encountered in artificial intelligence. The CNN is one of the most representative network structures of deep learning (deep learning) technology and has been very successful in the field of image processing and recognition.

In the field of medical electronics, the early detection of disease, allows to limit the spread of the disease which amounts to saving human lives. For this reason, modern medicine requires more and more electronic equipment of new technology. The latter needs maintenance and technological updates provided by specialists in medical electronics and image processing.

Computer-aided diagnosis of skin cancer is becoming increasingly necessary given the exponential growth of the image to be assessed each year. Different research has been conducted either to automatically detect lesions in images using computer-aided detection systems or to provide a second opinion about the lesion detected through diagnostic systems assisted by computer. The main objective of this research is to develop an automatic aid system to properly classify different pathologies of skin cancers into two categories namely benign and malignant.

Keywords: Artificial intelligence, machine learning, deep learning, classification, skin cancer, preprocessing, CNN, ResNet18, VGG16.

في السنوات الأخيرة ظهر التعلم العميق وخاصة الشبكات العصبية الملتفة (CNN) على وجه التحديد لحل المشكلات التي تواجه الذكاء الاصطناعي. تعد (CNN) واحدة من أكثر هياكل الشبكات تمثيلا لتكنولوجيا التعلم العميق وقد حققت نجاحا كبيرا في مجال معالجة الصور والتعرف عليها.

في مجال الإلكترونيات الطبية يسمح الكشف المبكر عن المرض بالحد من انتشار المرض الذي يصل إلى حد إنقاذ حياة البشر. لهذا السبب، يتطلب الطب الحديث المزيد والمزيد من المعدات الإلكترونية للتكنولوجيا الجديدة. يحتاج هذا الأخير إلى صيانة وتحديثات تكنولوجية يقدمها متخصصون في الإلكترونيات الطبية ومعالجة الصور.

أصبح التشخيص بمساعدة الكمبيوتر لسرطان الجلد ضروريا بشكل متزايد نظرا للنمو الهائل للصورة التي سيتم تقييمها كل عام. تم إجراء أبحاث مختلفة إما للكشف تلقائيا عن الأوقات في الصور باستخدام أنظمة للكشف بمساعدة الكمبيوتر أو لتقديم رأي ثان حول الآفة المكتشفة من خلال أنظمة التشخيص لتشخيص بمساعدة الكمبيوتر. الهدف الرئيسي من هذا البحث هو تطوير نظام مساعدة تلقائي لتصنيف أمراض مختلفة من سرطانات الجلد بشكل صحيح إلى فئتين هما الحميدة والخبيثة.

الكلمات المفتاحية: الذكاء الاصطناعي، التعلم الآلي، التعلم العميق، التصنيف، سرطانات الجلد؛ المعالجة المسبقة، CNN، VGG16 ، ResNet18.

TABLES DES MATIÈRES

Résumé	A
Abstract	B
Résumé en arabe	C
Table des Matières	D
Liste des figures	J
Abréviation	M

INTRODUCTION GENERALE 01

CHAPITRE I : L'ÉTAT DE L'ART SUR LE CANCER DE LA PEAU

I.1. Introduction	05
I.2. Structure de la peau	05
I.2.1. Epiderme	06
I.2.2. Derme	07
I.2.3. Hypoderme	08
I.3. Cancer de la peau	08
I.3.1. Différents types de cancer de la peau	09
I.3.1.1. Carcinome	09
I.3.1.1.1. La Keratose Acnitique	10
I.3.1.1.2. Le Carcinome Épidermoïde	10
I.3.1.1.3. Le Carcinome Basocellulaire	10
I.3.1.2. Mélanome	11
I.3.2. Les facteurs de risque	12
I.3.2.1. Exposition aux rayons ultraviolets (UV)	12
I.3.2.2. Antécédents familiaux	12
I.3.2.3. Peau claire	12
I.3.2.4. Exposition professionnelle	12
I.3.2.5. Antécédents de coups de soleil graves	12
I.3.2.6. Immunité affaiblie	12

I.3.2.7. Exposition aux radiations	13
I.4. Techniques de détection du cancer de la peau	13
I.4.1. Dermoscopie	13
I.4.2. Microscopie confocale	14
I.4.3. Tomographie optique cohérente	14
I.4.4. Echographie haute fréquence	15
I.4.5. Spectroscopie d'impédance électrique	16
I.4.6. Tomographie d'impédance électrique	16
I.5. Classification du cancer de la peau	17
I.5.1. Les caractéristiques des images de la peau	17
I.5.1.1. Texture	17
I.5.1.2. Couleur	18
I.5.1.3. Lésions cutanées	18
I.5.1.4. Vascularisation	18
I.5.1.5. Épaisseur	18
I.5.1.6. Hydratation	18
I.5.1.7. Élasticité	18
I.5.1.8. Texture de surface	18
I.5.2. Problématique	18
I.5.3. Cancer de la peau	19
I.6. Conclusion	20

CHAPITRE II : TRAITEMENT DES IMAGES MEDICALES

II.1. Introduction	22
II.2. Les images médicales	22
II.2.1. Définition	22
II.2.2. Objectif	23
II.2.3. Caractéristiques de l'image médicale	23
II.2.3.1. Le pixel	23
II.2.3.2. Dimension et Résolution	23

II.2.3.3. Voisinage	23
II.2.3.4. Luminance	24
II.2.3.5. Bruit	24
II.2.3.6. Contour	24
II.3. Traitement des images médicales	24
II.3.1. Acquisition de l'image	25
II.3.1.1. Imagerie par Résonance Magnétique (IRM)	25
II.3.1.2. Image par rayons X	25
II.3.1.2.1. Tomodensitométrie (TDM)	25
II.3.1.2.2. Radiographie	26
II.3.1.3. Image ultra son	26
II.3.2. Prétraitement des images médicales	26
II.3.2.1. Correction des artéfacts	26
II.3.2.2. Normalisation des intensités	27
II.3.2.3. Réduction du Bruit	27
II.3.3. Importance du prétraitement	27
II.3.3.1. Les histogrammes	27
II.3.3.1.1. Principe	27
II.3.3.1.2. Modifications d'histogrammes	29
II.3.3.1.2.1. Egalisation de l'histogramme	29
II.3.3.1.2.2. Étirement d'histogramme	30
II.3.3.1.2.3. L'égalisation adaptative de l'histogramme	31
II.3.3.2. Les ondelettes	32
II.4. Classification des images médicales	32
II.4.1. Les Méthodes de classification	33
II.4.1.1. Les Méthodes supervisées	33
II.4.1.1.1. Réseaux de neurones convolutionnels (CNN)	34
II.4.1.1.2. Machines à vecteurs de support (SVM)	34
II.4.1.1.3. Forêts d'arbres décisionnels (Random Forests)	34
II.4.1.1.4. Réseaux de neurones classiques (ANN)	34
II.4.1.1.5. Réseaux de neurones récurrents (RNN)	34
II.4.1.2. Les méthodes non supervisées	34

II.4.1.2.1. Clustering K-means	34
II.4.1.2.2. Analyse en composantes principales (PCA)	35
II.4.1.2.3. Clustering hiérarchique	35
II.4.1.2.4. Décomposition en valeurs singulières (SVD)	35
II.4.1.2.5. Algorithmes de mélange de gaussiennes (GMM)	35
II.4.1.2.6. Clustering spectral	35
II.4.2. Classification des images et l'apprentissage machine	35
II.5. Conclusion	37

CHAPITRE III : LES APPUIS MAJEURS DE L'INTELLIGENCE ARTIFICIELLE

III.1. Introduction	39
III.2. L'apprentissage automatique & l'apprentissage profond	40
III.2.1. L'apprentissage automatique (Machine Learning (ML))	41
III.2.1.1. Les types de l'apprentissage automatique	41
III.2.1.1.1. L'apprentissage supervisé	41
III.2.1.1.2. L'apprentissage non supervisé	41
III.2.1.1.3. L'apprentissage semi-supervisé	42
III.2.1.1.4. L'apprentissage par renforcement	42
III.2.2. L'apprentissage profond (Deep learning)	42
III.2.2.1. Les algorithmes de l'apprentissage profond	43
III.2.2.1.1. Réseaux neuronaux convolutifs (CNN)	43
III.2.2.1.2. Réseaux neuronaux récurrents (RNN)	43
III.2.2.1.3. Réseaux de fonction de base radiale (RBFN)	43
III.2.2.1.4. Réseaux de mémoire à long et court terme (LSTM)	43
III.2.2.1.5. Réseaux adversariaux génératifs (GAN)	44
III.2.2.1.6. Machines de Boltzmann restreintes (RBM)	44
III.2.2.2. Les applications de l'apprentissage profond	44
III.2.3. Différences entre machine learning & deep learning	44

III.2.3.1. Données et complexité des tâches	45
III.2.3.2. Ingénierie des caractéristiques	45
III.2.3.3. Interprétabilité	45
III.2.3.4. Puissance de calcul	45
III.3. Les réseaux neurones	45
III.3.1. Les neurones biologiques	45
III.3.2. les réseaux de neurones artificiels (RNA)	46
III.3.3. Les réseaux de neurones convolutifs	46
III.3.3.1. Les principales couches du CNN	47
III.3.3.1.1. Couche d'entrée	47
III.3.3.1.2. Couche de Convolution (CONV)	47
III.3.3.1.3. Couche de Pooling (POOL)	48
III.3.3.1.4. Couche de Correction ReLU	49
III.3.3.1.5. Couche Entièrement Connectée (FC)	49
III.3.3.1.6. Couche Logistique ou Softmax (LOSS)	50
III.3.3.1.7. Couche de Sortie (output Layer)	50
III.3.3.2. Les différentes architectures du CNN	50
III.3.3. 2.1. Le LeNet	50
III.3.3. 2.2. Le AlexNet	51
III.3.3. 2.3. Le VGGNet	51
III.3.3. 2.4. Le Google-Net (Inception)	52
III.3.3. 2.5. Le ResNet	52
III.3.3.3. L'apprentissage par transfert	53
III.3.3.4. Les Avantages et les inconvénients du CNN	54
III.3.3.4.1. Avantages du CNN	54
III.3.3.4.2. Inconvénients du CNN	54
III.4. Conclusion	54
	55

CHAPITRE IV : MISE EN ŒUVRE DE LA CLASSIFICATION

IV.1. Introduction	57
--------------------	----

IV.2. Environnement de développement	57
IV.2.1. Outil de développement : MATLAB R2022b	58
IV.2.1.1. Définition	58
IV.2.2. Base de données	58
IV.3. Les architecture du VGG16 & ResNet18 : Modèles (CNN)	58
IV.3.1. Le modèle ResNet18 (Résiduel Network)	58
IV.3.2. Le modèle VGG16 (Visual Graphics Group)	60
IV.4. Conception du système	61
IV.4.1. Objectif	61
IV.4.2. Schéma général de conception	61
IV.5. Évaluation des performances de classification	63
IV.5.1. Evaluation de la robustesse	63
IV.5.2. Evaluation de la précision (Accuracy)	63
IV.6. Résultats expérimentaux	64
IV.6.1. Présentation des résultats	64
IV.6.2. Analyse et discussion	64
IV.7. Conclusion	71

CHAPITRE V : CONCLUSION GÉNÉRALE

V.1. Récapitulatif	72
V.2. Perspectives	73

BIBLIOGRAPHIE	74
----------------------	----

Chapitre I	Page
Figure I.1 - Structure de la peau.	06
Figure I.2 - Couches de l'épiderme.	07
Figure I.3 - Différents type de cancer de la peau.	09
Figure I.4 - La keratose acnitique.	10
Figure I.5 - Le carcinome Épidermoïde.	11
Figure I.6 - Le mélanome Cutané.	11
Figure I.7 - La dermoscopie pour détecter le cancer cutanée.	13
Figure I.8 - Microscope qui permet de détecter le cancer de la peau plus rapidement	14
Figure I.9 - La Tomographie optique cohérente pour le diagnostique du carcinome basocellulaire.	15
Figure I.10 - Echographie haute fréquence.	15
Figure I.11 - Spectroscopie d'impédance électrique.	16
Figure I.12 - La Tomographie d'impédance électrique.	17
 Chapitre II	
Figure II.1 - Traitement d'images médicales.	24
Figure II.2 - Histogramme d'une image de cancer de la peau en couleur.	28
Figure II.3 - Principe de la modification d'histogramme.	29
Figure II.4 - Image avant et après égalisation de l'histogramme.	30
Figure II.5 - Augmentation du contraste par étirement d'histogramme.	31
Figure II.6 - Augmentation du contraste d'une image par étirement d'histogramme.	31

Figure II.7 - Image améliorée par égalisation d’histogramme adaptative.	32
Figure II.8 - Image original et image après la méthode d’ondelette.	32
Chapitre III	
Figure III.1 - Affiliation de deep learning (relation entre I.A. et M.L et deep learning).	39
Figure III.2 - Le machine learning et le deep learning.	40
Figure III.3 - Les types de l’apprentissage automatique.	42
Figure III.4 - Modèle d’un neurone artificiel.	46
Figure III.5 - Architecture standard d’un réseau de neurone convolutif.	47
Figure III.6 - Les principales couches de traitement d’un CNN	47
Figure III.7 - Exemple de principe du filtre convolutionnel.	48
Figure III.8 - Exemple d’une opération de Max pooling de taille 2×2 .	48
Figure III.9 - Principe de la fonction ReLu.	49
Figure III.10 - Couche Entièrement Connectée (FC)	49
Figure III.11 -Histoire évolutive des CNNs montrant les innovations architecturales.	50
Figure III.12 - L’architecture LeNet.	
Figure III.13 - L’architecture d’AlexNet.	51
Figure III.14 - L’architecture de VGGNet.	51
Figure III.15 - L’architecture de Google-Net.	52
Figure III.16 - L’architecture ResNet.	52
Figure III.17 - L’apprentissage par transfert.	53
	53

Chapitre IV

Figure IV.1 - L'architecture du ResNet18	59
Figure IV.2 - L'architecture du VGG16.	60
Figure IV.3 - Schéma général de conception.	62
Figure IV.4 - Le modèle de la précision (accuracy) pour l'apprentissage et le teste avec ResNet18.	65
Figure IV.5 - Le modèle de la précision (accuracy) pour l'apprentissage et le teste avec VGG16.	66
Figure IV.6 - Résultats après le prétraitement.	67
Figure IV.7 - Le modèle de la précision (accuracy) de la classification avec ResNet18.	68
Figure IV.8 - Le modèle de la précision (accuracy) de la classification avec VGG16.	69
Figure IV.9 - Le modèle de la précision (accuracy) pour l'apprentissage et le teste.	70
Figure IV.10 - Le modèle de perte (loss) pour l'apprentissage et le teste.	70

UV	Ultraviolets
CNN	Convolutional Neural Network
ResNet18	Residual Network with 18 layers
VGG16	Visual Geometry Group
UVA	Ultraviolet A
KA	Kératose Actinique
CE	Carcinome Épidermoïde
CBC	Carcinome Basocellulaire
TOC	Tomographie Optique Cohérente
SIE	Spectroscopie d'Impédance Électrique
TIE	Tomographie d'Impédance Électrique
AlexNet	Réseau de Neurones Convolutifs développé par Alex Krizhevsky
IRM	Imagerie par Résonance Magnétique
PPP	Points Par Pouce
LA	L'apprentissage automatique
LP	L'apprentissage Profond
TDM	Tomodensitométrie
PQN	Processus de Quantification des Niveaux
GIF	Grand Nombre d'Informations
MNG	Mesure des Niveaux de Gris
MDI	Modifier les Caractéristiques de l'Image
EPI	Étendre la Dynamique de l'Image

EPO	Équipopulation
EHI	Égalisation d'Histogrammes
HC	Histogramme Cumulé
AHE	Adaptive Histogram Equalization
SVD	Singular Value Decomposition
ROI	Region of Interest
SVM	Support Vector Machine
ANN	Artificial Neural Network
RNN	Recurrent Neural Network
PCA	Principal Component Analysis
GMM	Gaussian Mixture Model
ML	Machine Learning
DL	Deep Learning
RNA	Réseaux de Neurones Artificiels
LSTM	Long Short-Term Memory
RBFN	Réseaux de Fonction de Base Radiale
GAN	Réseaux Adversariaux Génératifs
RBM	Machines de Boltzmann Restreintes
MLP	Perceptrons Multicouches
CONV	Couche de Convolution
POOL	Couche de Pooling
ReLU	Rectified Linear Unit
FC	Couche Entièrement Connectée
LOSS	Couche Logistique ou Softmax

ISIC	International Skin Imaging Collaboration
Adam	Adaptive Moment Estimation
RMSprop	Root Mean Square Propagation
SGDM	Stochastic Gradient Descent with Momentum
VP	Vrais Positifs
VN	Vrais Négatifs
FN	Faux Négatifs
FP	Faux Positifs

INTRODUCTION GENERALE

De nos jours, le diagnostique par imagerie est un outil inestimable dans la médecine. L'image mammographie (1989), l'image à résonance magnétique nucléaire (RMN en 1971), le scanner hélicoïdal (CT en 1990), la tomographie (1927) et d'autres modalités d'imagerie médicale fournissent des moyens efficaces pour la configuration de l'anatomie d'un sujet, la détection d'anomalies, et à faire des mesures sans intervention directe. Ces technologies ont augmenté la connaissance de l'anatomie normale et malade pour la recherche médicale. Ils sont un composant critique dans le diagnostic et la planification du traitement.

Avec la croissance de la taille et du nombre d'images médicales, l'utilisation d'ordinateurs pour faciliter leur traitement et leur analyse est devenue nécessaire. En particulier, les algorithmes de segmentation et de classification d'image, qui jouent un rôle crucial dans plusieurs applications d'imagerie médicale en automatisant la délimitation de structures anatomiques et d'autres régions d'intérêt.

Les méthodes de classification performantes varient largement selon l'application spécifique, la modalité de l'image et d'autres facteurs. Chaque modalité d'image a ses propres caractéristiques. Il n'y a actuellement aucune méthode de classification simple qui rapporte des résultats acceptables pour chaque image médicale. Les méthodes qui existent sont plus générales et peuvent être appliquées à une variété de données. Cependant, les méthodes qui sont spécialisées à des applications particulières peuvent souvent réaliser la meilleure performance en prenant en considération des connaissances a priori.

Le cancer de la peau est l'une des formes les plus répandues de cancer dans le monde, avec une incidence en constante augmentation ces dernières décennies. Le nombre de nouveaux cas annuels de mélanomes augmente de 5 % par an depuis 50 ans, une croissance supérieure à celle de tout autre cancer. Il englobe un ensemble de maladies malignes qui affectent les cellules de la peau, l'organe le plus étendu du corps humain. Ce type de cancer peut se manifester sous différentes formes, dont les plus courantes sont le carcinome basocellulaire, le carcinome épidermoïde et le mélanome.

L'exposition excessive aux rayons ultraviolets (UV), qu'elle soit due au soleil ou au lit de bronzage artificiel, est le principal facteur de risque de développement du cancer de la peau. Les zones du corps les plus souvent touchées sont celles régulièrement exposées au soleil, telles que le visage, le cou, les bras et les mains. Cependant, le cancer de la peau peut également se développer dans des zones moins exposées.

Si le diagnostic intervient tôt dans l'évolution de la lésion, le taux de survie relative à 5 ans est de 88 % pour les stades localisés. La détection d'un mélanome à un stade précoce, alors que relativement peu de signes de malignité sont visibles sur la lésion est donc très souhaitable, mais cette opération est difficile. Cette distinction peut parfois être complexe même pour les dermatologues expérimentés, en raison de la variabilité des caractéristiques visuelles des lésions cutanées.

L'avènement du deep learning, en particulier des réseaux neuronaux convolutionnels (CNN), a révolutionné la capacité à extraire des informations pertinentes à partir d'images médicales, offrant ainsi de nouvelles perspectives dans le domaine du diagnostic du cancer de la peau. Dans ce contexte, ce projet vise à explorer l'efficacité des techniques de deep learning, en utilisant des architectures de réseaux populaires telles que ResNet18, VGG16 et d'autres, pour la classification automatique des lésions cutanées en tumeurs malignes et bénignes.

Dans cette étude, nous abordons la classification du cancer de la peau comme un problème de vision par ordinateur supervisé, où l'objectif est d'entraîner un modèle à partir d'un ensemble de données étiquetées, afin de prédire avec précision la nature maligne ou bénigne des lésions cutanées sur de nouvelles images. L'objectif ultime de ce projet est de développer un outil de diagnostic automatique qui pourrait assister les dermatologues dans leurs pratiques cliniques quotidiennes, en fournissant des recommandations précises et rapides pour la classification des lésions cutanées. Une telle solution pourrait contribuer à améliorer l'efficacité du diagnostic, à réduire les délais d'attente pour les patients et à faciliter l'accès aux soins de santé dans les régions où les ressources médicales sont limitées.

Ce manuscrit est constitué de quatre chapitres organisés comme suit :

- Le premier chapitre est introductif et présente une suite de définitions qui permettront de mieux appréhender le sujet des images médicales, plus particulièrement le cancer de la peau.

Nous abordons différents types de cancer de la peau ainsi que leur classification et les techniques de détection de ce dernier. Une présentation de différents modèles de classification qui ont suscité de nombreux travaux dans ce domaine au cours de ces dernières années.

- Nous introduisons au deuxième chapitre des méthodes de traitement des images médicales qui sont la morphologie mathématique, comme outil d'amélioration de l'image. Une présentation de différentes méthodes de classification qui sont utilisées, parmi lesquelles les méthodes supervisées et non supervisées.
- Le chapitre trois est dédié à l'étude de l'intelligence artificielle (IA) et les différents types d'apprentissage automatique et profond. Enfin, une attention particulière a été accordée à la méthode des réseaux de neurones convolutifs (CNN).
- Dans le chapitre quatre, un système de la classification automatique du cancer de la peau est présenté pour classer les tumeurs comme étant bénignes ou malignes. On y trouve également les résultats obtenus.

Enfin, une conclusion et les perspectives envisagées sont présentées en dernier lieu.

L'ÉTAT DE L'ART SUR LE CANCER DE LA PEAU

Au cours des trente dernières années, l'augmentation du taux d'incidence du cancer de la peau a été la plus importante parmi tous les cancers. Le diagnostic précoce du cancer de la peau s'avère important pour minimiser les risques d'évolution en cancer généralisé et pour améliorer les chances de succès thérapeutique et de survie à long terme, soulignant ainsi l'importance des efforts de sensibilisation, de dépistage et de recherche dans ce domaine.

Dans ce chapitre, on abordera l'approche médicale de l'imagerie du peau, pour situer le contexte dans lequel l'application que nous cherchons à développer va être utilisée. Nous présentons le cancer de la peau et des changements bénins et malins qui peuvent se produire, différents types de cancer de la peau ainsi que leur classification. Cependant, cette approche n'est pas exhaustive et est donnée uniquement dans le but de faciliter la compréhension de la problématique pour en déduire des méthodes de détection et classifications.

I.1. Introduction

Le cancer de la peau représente un défi majeur pour la santé publique, avec des implications importantes en termes de diagnostic précoce, de traitement et de prévention. Pour mieux appréhender cette maladie, il est crucial de comprendre la structure complexe de la peau. Celle-ci est composée de plusieurs couches, dont l'épiderme et le derme, qui jouent des rôles essentiels dans la protection de l'organisme contre les agressions extérieures et dans la régulation de divers processus physiologiques.

Dans le cadre du cancer de la peau, on distingue principalement deux types de lésions : le carcinome et le mélanome. Le carcinome, qui se développe à partir des cellules épithéliales de la peau, est le type le plus courant et comprend plusieurs sous-types tels que le carcinome basocellulaire et le carcinome spin cellulaire. Le mélanome, quant à lui, se forme à partir des cellules productrices de pigment de la peau, appelées mélanocytes et représente une forme plus agressive de cancer de la peau, avec un risque de métastases plus élevé.

Pour détecter et diagnostiquer précocement le cancer de la peau, diverses techniques d'imagerie et de biopsie sont utilisées. Parmi celles-ci, on trouve la dermoscopie, qui permet une visualisation en profondeur des lésions cutanées, la microscopie confocale, qui offre une résolution cellulaire élevée sans nécessité de biopsie invasive, la tomographie optique cohérente, qui permet une caractérisation en profondeur des tissus cutanés, l'échographie haute fréquence, qui offre une visualisation des structures sous-cutanées, ainsi que la spectroscopie d'impédance électrique et la tomographie d'impédance électrique, qui permettent une analyse des propriétés électriques des tissus cutanés. En combinant ces différentes techniques, les professionnels de la santé sont en mesure de détecter précocement les lésions suspectes, de les caractériser de manière précise et de guider efficacement le choix du traitement le plus approprié pour chaque patient.

I.2. Structure de la peau

La peau est l'un des plus importants organes du corps en termes de superficie et de poids. Chez l'adulte, elle peut atteindre une surface de 2 m² et un poids de 4 kg. Son épaisseur varie de moins de 1 mm sur les paupières à un peu plus de 4 mm dans le dos. La peau forme une barrière protectrice entre l'organisme et l'environnement extérieur. Elle est formée de trois couches de tissus superposées qui sont, de l'extérieur vers l'intérieur : l'épiderme, le derme et l'hypoderme (figure I.1).

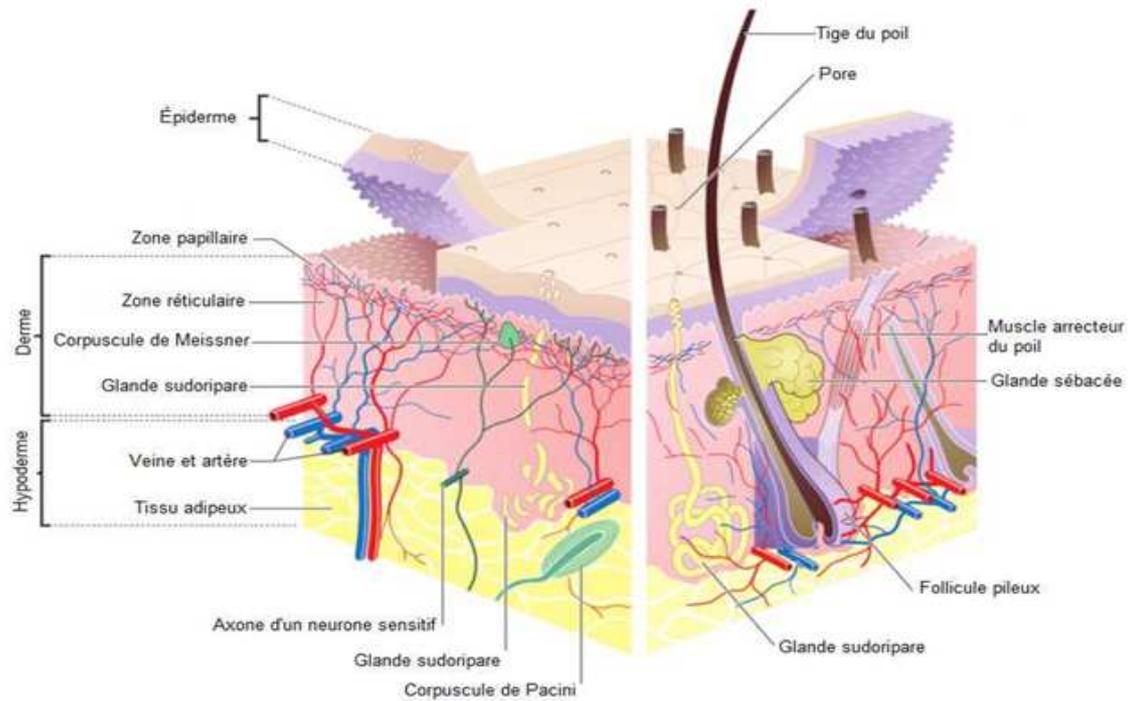


Figure I.1 - Structure de la peau. [1]

I.2.1. Epiderme

L'épiderme est la partie externe de la peau et comprend habituellement quatre couches (Figure I.2) : la couche cornée (stratum corneum), la couche granuleuse (stratum granulosum), la couche des cellules à épines (stratum spinosum) et la couche basale (stratum basale). La paume des mains et la plante des pieds comprennent une cinquième couche épidermique, le stratum lucidum, située entre le stratum corneum et le stratum granulosum. Il mesure en moyenne un millimètre d'épaisseur (il est plus épais au niveau de la paume des mains et de la plante des pieds).

Quatre types de cellules distinctes composent ces couches : les kératinocytes, les mélanocytes, les cellules de Langerhans et les cellules de Merkel.

- Les kératinocytes représentent environ 90 % des cellules de l'épiderme et produisent la kératine, une protéine permettant de protéger et d'imperméabiliser la peau. Ces cellules sont synthétisées par mitose au niveau du stratum basal repoussant ainsi les kératinocytes plus matures vers le stratum spinosum puis vers le stratum granulosum où ils finissent par mourir. Le stratum corneum est entièrement formé de cellules kératinisées mortes qui protègent la peau des agressions extérieures. Le stratum corneum est entièrement formé de cellules kératinisées mortes qui protègent la peau des agressions extérieures.

- Les mélanocytes, moins nombreux, constituent le quart des cellules du stratum basal. Ces cellules dendritiques permettent de produire la mélanine, un pigment dont la couleur varie du jaune au brun-noir et qui détermine la couleur de la peau. Comme les pigments de mélanine protègent les cellules des rayons ultraviolets (UV), les individus ayant une peau moins pigmentée présentent un risque accru d'insolation et de cancers cutanés. Une exposition au soleil stimule la synthèse des pigments de mélanine qui sont transférés via les dendrites des mélanocytes aux kératinocytes où ils forment un bouclier protégeant l'acide désoxyribonucléique (ADN) des rayons UV.
- L'épiderme comprend également les cellules de Langerhans qui sont associées au système immunitaire. Elles se retrouvent principalement dans le stratum spinosum et en moins grand nombre dans le stratum granulosum.
- Finalement, l'épiderme comporte quelques cellules de Merkel jouant le rôle de récepteurs sensoriels du toucher. Ces cellules sont liées à des terminaisons nerveuses sensibles et se situent à la jonction de la couche basale et du derme.

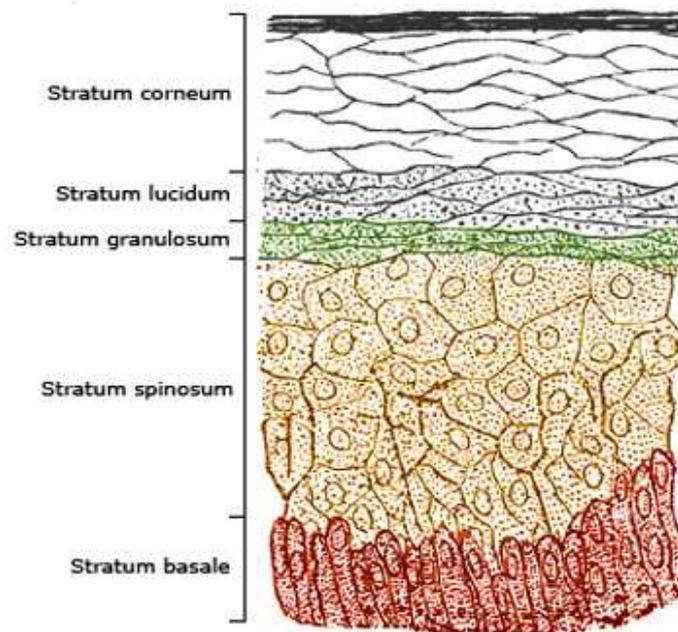


Figure I.2 - Couches de l'épiderme. [2]

I.2.2. Derme

Le derme, situé sous l'épiderme, est un tissu conjonctif essentiellement formé de collagène et de fibres élastiques soutenues par une matrice gélatineuse de glycoprotéines. Tel qu'illustré à la figure I.1, le derme est divisé en deux régions : la zone papillaire et la zone réticulaire.

- La zone papillaire, correspondant à la partie supérieure du derme, est constituée d'un tissu conjonctif lâche dont les fibres collagènes et élastiques sont plutôt orientées perpendiculairement à la surface de la peau. Cette zone très irrégulière donne à la surface du derme un relief bosselé.
- La zone réticulaire représente 80 % du derme et est composée d'un tissu conjonctif dense comprenant des fibres collagènes et élastiques orientées parallèlement à la surface de la peau.
- On retrouve également dans le derme de nombreuses terminaisons nerveuses et une population cellulaire constituée principalement de fibroblastes et de cellules associées au système immunitaire. La vascularisation du derme est importante, car elle alimente également l'épi derme en nutriments par diffusion. Les vaisseaux sanguins sont organisés en deux réseaux : Les plexus vasculaires superficiels et profonds.

I.2.3. Hypoderme

Le tissu hypodermique sert à l'isolation de l'ensemble du corps, est utilisé comme réserve énergétique, protège la peau et permet sa mobilité par rapport aux structures sous-jacentes. La frontière entre derme réticulaire profond et hypoderme est abrupte entre un derme conjonctif principalement fibreux à une région sous-cutanée riche en adipocytes. Les deux structures sont cependant structurellement et fonctionnellement imbriquées grâce aux réseaux vasculaires et nerveux et aux appendices épidermiques. Les follicules pileux en phase active de croissance s'étendent jusque dans la graisse sous-cutanée et les glandes apocrines et écrins de transpiration sont normalement confinées dans ces profondeurs cutanées. Les adipocytes originaires du mésenchyme sont les principales cellules de l'hypoderme et sont regroupées en lobules.

I.3. Cancer de la peau

Le cancer de la peau est une forme de cancer très répandue qui afflige l'épiderme. Il prend racine dans les mélanocytes, les cellules en charge de la production de la mélanine, qui vont se dupliquer en très grand nombre jusqu'à provoquer une tumeur. Cette anomalie des mélanocytes est en grande partie due à l'exposition aux UVA. Détecté précocement, le cancer de la peau est un cancer bénin. L'exérèse (élimination) des tissus cancéreux se fait par chirurgie locale. S'il est détecté tardivement, son pronostic est moins bon, notamment si des cellules cancéreuses ont migré et se sont disséminées dans l'ensemble de l'organisme.

I.3.1. Différents type de cancer de la peau

Partout dans le monde, les chiffres du cancer de la peau sont en constante augmentation. Toutes les 14 secondes, un cancer de la peau est diagnostiqué dans le monde. Un tiers des cancers diagnostiqués dans le monde est un cancer de la peau et 10% d'entre eux sont mortels.

Il existe deux types de cancers de la peau : les carcinomes, qui ont une malignité locale et pour lesquels la chirurgie suffit la plupart du temps, sauf dans de très rares cas où les traitements oncologiques sont nécessaires (90 % des cancers de la peau) et les mélanomes dans lesquels les cellules se multiplient rapidement et qui ont une tendance à envahir le reste de l'organisme si la lésion est enlevée tardivement : ce sont les plus dangereux.

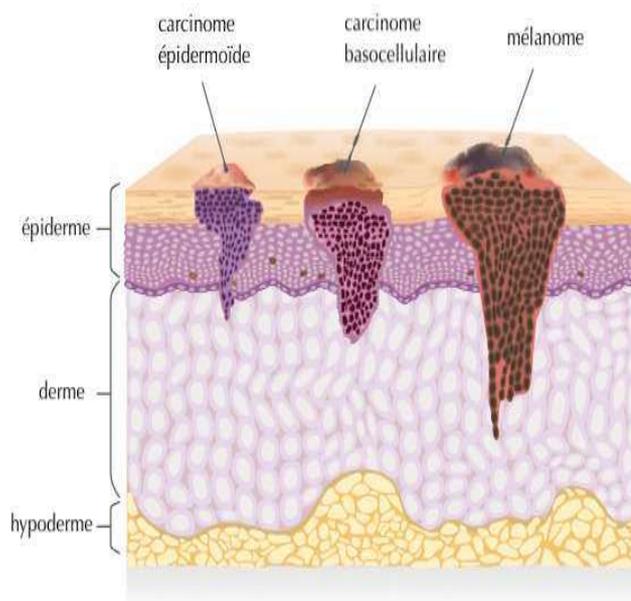


Figure I.3 - Différents type de cancer de la peau. [3]

I.3.1.1. Carcinome

Le carcinome est une tumeur maligne qui se développe à partir des cellules de l'épiderme. Il existe deux principaux types de carcinomes cutanés : le carcinome basocellulaire, le plus fréquent et le carcinome épidermoïde. Le carcinome basocellulaire touche principalement le visage et évolue localement sans métastases, tandis que le carcinome épidermoïde peut parfois atteindre les ganglions du cou, nécessitant parfois une radiothérapie complémentaire. [3]

I.3.1.1.1. La keratose acnitique

La kératose actinique (KA) est une lésion précancéreuse due à l'exposition trop fréquente de la peau à la lumière solaire et qui se développe sur les zones découvertes de la peau. On considère qu'il s'agit du premier stade menant au développement des cancers cutanés tels que le carcinome épidermoïde. [4]



Figure I.4 - La keratose acnitique. [4]

I.3.1.1.2. Le Carcinome Épidermoïde

Le carcinome épidermoïde (CE), ou également appelé carcinome spino-cellulaire, est le deuxième cancer cutané le plus répandu. Il s'agit d'un cancer à forte agressivité. Dans la plupart des cas les carcinomes épidermoïde sont causés par une exposition chronique aux rayons du soleil. Il s'agit d'une croissance incontrôlée de kératinocytes anormaux. 40 à 60% des carcinomes épidermoïde proviennent de kératoses actiniques non traitées.

I.3.1.1.3. Le carcinome basocellulaire

Le carcinome basocellulaire (CBC) est le cancer de la peau – et de tous les organes confondus- le plus fréquent mais le moins agressif. Généralement causés par la combinaison des expositions cumulées et intenses aux UV et des expositions occasionnelles, les carcinomes basocellulaires se développent à partir des cellules basales de la peau dans la couche la plus profonde de l'épiderme.



Figure I.5 - Le carcinome épidermoïde. [4]

I.3.1.2. Mélanome

Le mélanome est un type de cancer de la peau qui se développe à partir des cellules de la peau appelées mélanocytes, responsables de la production de mélanine, le pigment qui donne sa couleur à la peau. Ce cancer peut se manifester par des taches ou des nodules de couleur brune ou noire sur la peau. Le mélanome peut être diagnostiqué par des changements dans la taille, la forme ou la couleur d'un grain de beauté existant. Il existe plusieurs types de mélanomes, dont le mélanome superficiel extensif, le mélanome nodulaire, le mélanome de type lentigo malin et le mélanome lentigineux des extrémités. Le mélanome est considéré comme l'une des formes les plus graves de cancer de la peau en raison de sa capacité à se propager rapidement et à causer des métastases. La détection précoce est essentielle pour un pronostic favorable, soulignant l'importance de surveiller les changements cutanés et de consulter un professionnel de santé en cas de doute.



Figure I.6 - Le Mélanome cutané. [4]

I.3.2. Les facteurs de risque

Les facteurs de risque pour le cancer de la peau varient selon le type de cancer de la peau considéré. Cependant, certains facteurs de risque communs incluent :

I.3.2.1. Exposition aux rayons ultraviolets (UV)

L'exposition excessive au soleil ou aux rayons UV artificiels provenant des lits de bronzage est l'un des principaux facteurs de risque pour la plupart des types de cancer de la peau. Les dommages causés par les UV peuvent endommager l'ADN des cellules cutanées, augmentant ainsi le risque de cancer.

I.3.2.2. Antécédents familiaux

Les personnes ayant des antécédents familiaux de cancer de la peau ont un risque accru de développer la maladie. Les mutations génétiques héritées peuvent jouer un rôle dans la susceptibilité au cancer de la peau.

I.3.2.3. Peau claire

Les personnes ayant une peau claire, qui brûle facilement et qui a peu ou pas de capacité à bronzer, ont un risque plus élevé de développer un cancer de la peau que celles ayant une pigmentation plus foncée.

I.3.2.4. Exposition professionnelle

Certains métiers exposent les travailleurs à des produits chimiques ou à des substances qui peuvent augmenter le risque de cancer de la peau.

I.3.2.5. Antécédents de coups de soleil graves

Les coups de soleil sévères, surtout lorsqu'ils surviennent pendant l'enfance, peuvent augmenter le risque de cancer de la peau à l'âge adulte.

I.3.2.6. Immunité affaiblie

Les personnes dont le système immunitaire est affaibli, que ce soit en raison d'une condition médicale sous-jacente ou de médicaments immunosuppresseurs, ont un risque accru de cancer de la peau.

I.3.2.7. Exposition aux radiations

Une exposition antérieure à des radiations, que ce soit pour un traitement médical ou pour d'autres raisons, peut augmenter le risque de cancer de la peau.

Il est important de noter que la présence de facteurs de risque n'entraîne pas nécessairement le développement d'un cancer de la peau, mais elle peut augmenter la probabilité de sa survenue. La réduction de l'exposition aux facteurs de risque modifiables et la surveillance régulière de la peau peuvent contribuer à réduire le risque de cancer de la peau et à détecter les anomalies précoces.

I.4. Techniques de détection du cancer de la peau

Étant donné l'ampleur du problème, plusieurs techniques ont été proposées pour assister les médecins dans le diagnostic précoce du cancer de la peau [5], [6] et [7]. La dermatologie est l'une des dernières spécialités médicales à avoir adopté l'instrumentation biomédicale et constitué une application clinique en forte émergence [8]. Les prochaines sous-sections présentent les principales techniques développées pour la détection des lésions cutanées malignes.

I.4. 1. Dermoscopie

La dermatoscopie est une technique d'examen de la peau qui permet aux dermatologues d'observer les structures cutanées en détail. En utilisant un dermatoscope, un instrument muni d'une lumière polarisée, les dermatologues peuvent examiner les lésions cutanées avec une plus grande précision. Cette méthode est particulièrement utile dans le diagnostic des mélanomes et d'autres cancers de la peau, car elle permet de détecter des caractéristiques invisibles à l'œil nu. [9]



Figure I.7 - La dermatoscopie pour détecter le cancer cutané. [10]

I.4.2. Microscopie confocale

La microscopie confocale est une technique d'imagerie en temps réel qui permet l'observation des tissus biologiques à des résolutions cellulaires. En dermatologie, elle est largement utilisée pour l'analyse des lésions cutanées, offrant une vision en profondeur des structures de la peau sans avoir recours à des biopsies invasives. La microscopie confocale permet d'identifier des caractéristiques morphologiques spécifiques des différentes affections cutanées, ce qui facilite le diagnostic différentiel entre les lésions bénignes et malignes. Son utilisation s'est répandue ces dernières années, offrant aux dermatologues un outil précieux pour la prise en charge des patients présentant des affections cutanées complexes. [11]



Figure I.8 - Microscope qui permet de détecter le cancer de la peau plus rapidement. [12]

I.4.3. Tomographie optique cohérente

La tomographie optique cohérente (TOC) est une technique d'imagerie non invasive qui permet la visualisation des structures tissulaires en profondeur. En dermatologie, la TOC est utilisée pour l'analyse des lésions cutanées, offrant une résolution micrométrique et la possibilité d'observer les couches de la peau sans prélèvement de tissu. Cette technique fournit des informations précieuses sur la morphologie des lésions cutanées, facilitant ainsi le diagnostic et la prise en charge des patients. La TOC est devenu un outil essentiel en dermatologie, permettant aux médecins d'obtenir des images détaillées et en temps réel des affections cutanées. [13]



Figure I.9 - La tomographie optique cohérente pour le diagnostic du carcinome basocellulaire. [14]

I.4.4. Echographie haute fréquence

L'échographie haute fréquence est une technique d'imagerie médicale qui utilise des ondes sonores à haute fréquence pour visualiser les tissus cutanés en profondeur. En dermatologie, cette technique est largement utilisée pour l'évaluation des lésions cutanées, permettant une visualisation détaillée des structures superficielles et profondes de la peau. Grâce à sa résolution élevée, l'échographie haute fréquence permet de distinguer les différentes couches de la peau, ainsi que les anomalies pathologiques telles que les tumeurs, les kystes et les lésions inflammatoires. Cette technique est non invasive et peut être utilisée pour le suivi des patients et la guidance des procédures dermatologiques. [15]

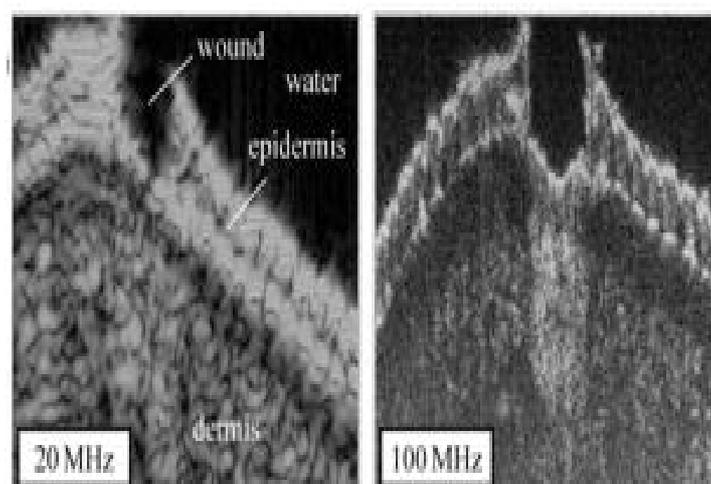


Figure I.10 - Echographie haute fréquence. [16]

I.4.5. Spectroscopie d'impédance électrique

La spectroscopie d'impédance électrique (SIE) est une technique puissante utilisée en sciences biomédicales pour étudier les propriétés électriques des tissus biologiques. En dermatologie, la SIE est utilisée pour évaluer les caractéristiques électriques des lésions cutanées et des tissus environnants. Cette technique repose sur l'application de signaux électriques à différentes fréquences et l'analyse de la réponse électrique du tissu. La SIE permet de détecter des anomalies telles que les tumeurs, les kystes et les lésions inflammatoires en mesurant les variations de l'impédance électrique des tissus. En tant qu'outil non invasif et relativement peu coûteux, la spectroscopie d'impédance électrique présente un grand potentiel pour le diagnostic et le suivi des affections cutanées. [17]



Figure I.11 - Spectroscopie d'impédance électrique.

I.4.6. Tomographie d'impédance électrique

La tomographie d'impédance électrique (TIE) est une technique d'imagerie médicale non invasive qui permet de reconstruire la distribution spatiale des propriétés électriques des tissus à l'intérieur du corps. En dermatologie, la TIE est utilisée pour visualiser les structures internes de la peau et évaluer les propriétés électriques des lésions cutanées. Cette technique repose sur la mesure des variations d'impédance électrique à travers la peau à l'aide de plusieurs électrodes placées autour de la zone d'intérêt. La TIE offre ainsi la possibilité d'obtenir des images tridimensionnelles des tissus cutanés, permettant une évaluation détaillée des lésions cutanées telles que les tumeurs, les kystes et les lésions inflammatoires. En tant qu'outil non invasif et sûr, la tomographie d'impédance électrique présente un grand potentiel pour le diagnostic et la surveillance des affections dermatologiques. [18]

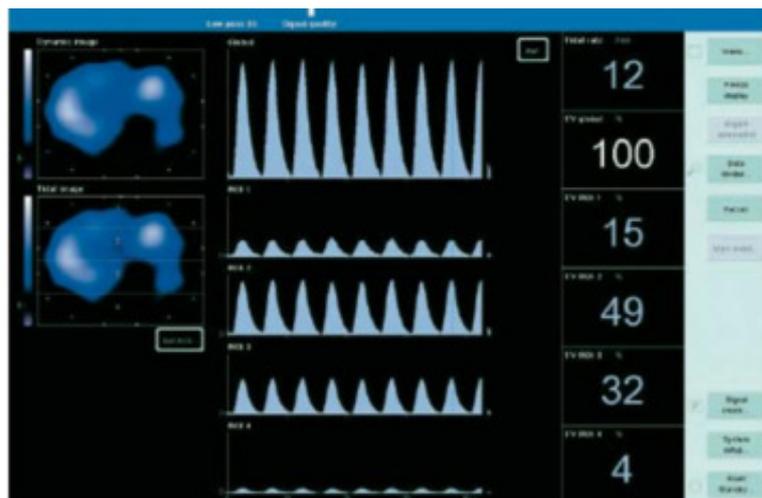


Figure I.12 - La tomographie d'impédance électrique. [19]

I.5. Classification du cancer de la peau

La classification du cancer de la peau distingue les tumeurs en deux catégories principales : les tumeurs malignes et les tumeurs bénignes. Les tumeurs malignes sont des cancers agressifs qui peuvent se propager à d'autres parties du corps, mettant en jeu le pronostic vital. En revanche, les tumeurs bénignes sont des amas de cellules non cancéreuses qui se développent lentement localement, sans produire de métastases et ne récidivent pas s'ils sont complètement enlevés.

La classification des images du cancer de la peau émerge comme une solution cruciale pour organiser, analyser et extraire des informations pertinentes à partir de ces ensembles de données complexes. Cette exploration approfondie des méthodes de classification, des enjeux et des applications dans le domaine de l'imagerie médicale vise à fournir un aperçu complet des progrès réalisés ainsi que des défis à relever.

I.5.1. Les caractéristiques des images de la peau

Les caractéristiques des images de la peau varient selon la méthode utilisée pour les capturer et les analyser. Voici quelques-unes des caractéristiques générales que l'on peut souvent observer dans les images de la peau :

I.5.1.1. Texture : La texture de la peau peut varier selon la région du corps, l'âge et d'autres facteurs. Les images peuvent montrer des détails fins tels que les pores, les ridules et les rides.

I.5.1.2. Couleur : La couleur de la peau peut varier selon la pigmentation naturelle de la personne ainsi que les conditions temporaires comme les rougeurs, les taches brunes ou les lésions cutanées.

I.5.1.3. Lésions cutanées : Les images de la peau peuvent révéler différentes lésions cutanées telles que des grains de beauté, des taches de naissance, des verrues, des acnés, des cicatrices, des ulcères, des plaies, des ecchymoses, etc.

I.5.1.4. Vascularisation : Certains types d'imagerie peuvent révéler la vascularisation de la peau, montrant les vaisseaux sanguins et leur réseau.

I.5.1.5. Épaisseur : L'épaisseur de la peau peut être évaluée visuellement dans les images, bien que des méthodes d'imagerie plus avancées puissent fournir des mesures plus précises de cette caractéristique.

I.5.1.6. Hydratation : Dans certaines images, l'hydratation de la peau peut être évidente, montrant une peau sèche ou une peau bien hydratée.

I.5.1.7. Élasticité : Bien que cela puisse être plus difficile à évaluer visuellement, certaines images peuvent fournir des indices sur l'élasticité de la peau, notamment en observant la façon dont elle réagit à la pression ou aux mouvements.

I.5.1.8. Texture de surface : Des images de haute résolution peuvent révéler des détails fins de la texture de surface de la peau, tels que les plis, les creux et les bosses.

I.5.2. Problématique

Comment concevoir et entraîner un modèle de deep learning, en particulier un réseau de neurones convolutifs (CNN) pour classifier efficacement les images de cancer de la peau en tumeurs malignes et bénignes, en tirant parti du transfert d'apprentissage et du redimensionnement progressif, tout en assurant l'interprétabilité du modèle pour les professionnels de la santé ?

Cette problématique soulève des questions clés telles que :

- Comment préparer et nettoyer les données d'images médicales de cancer de la peau pour l'entraînement du modèle ?
- Comment mettre en œuvre le transfert d'apprentissage pour améliorer les performances du modèle sur un petit ensemble de données ?
- Comment garantir l'interopérabilité du modèle pour permettre une interprétation facile des résultats par les professionnels de la santé ?

- Quelles mesures d'évaluation (matrice de confusion, précision, rappel, etc.) sont pertinentes pour évaluer la performance du modèle dans la classification des tumeurs malignes et bénignes ?

Cette approche s'inspire des bonnes pratiques utilisées dans des projets similaires, où le deep learning a été appliqué avec succès à la classification d'images médicales pour différents types de cancer.

I.5.3. Cancer de la peau

En comprenant mieux les fondements et les implications de la classification des images médicales, nous pouvons exploiter pleinement son potentiel pour améliorer les diagnostics, les traitements et les résultats cliniques, ouvrant ainsi la voie à de nouvelles avancées dans le domaine de la santé et du bien-être des patients [20]. Dans ce domaine médical, l'information, en particulier l'image, joue un rôle crucial. Cependant, pour obtenir un diagnostic précis dans un délai acceptable, ces images nécessitent un traitement spécifique et particulier. Malgré les avancées technologiques dans le domaine médical, et en particulier en imagerie médicale, l'étude de l'archivage de ces images reste un sujet de recherche et d'actualité.

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 la référence [21], Esteva et al, ont étudié les CNN préformés pour la classification du cancer de la peau et un grand ensemble de données a été utilisé dans leur étude. Dans la référence [22], 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 [23] ont été adoptées pour extraire les traits profonds des images dermoscopiques pour la classification des lésions cutanées [22]. Dans la référence [24], Massod et al, a proposé un modèle d'apprentissage semi-supervisé et auto-conseillé pour la détection du mélanome sur des images dermoscopiques. Dans la référence [25], 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.

I.6. Conclusion

La classification du cancer de la peau en lésions bénignes et malignes est cruciale pour un diagnostic précis et un traitement approprié. Les avancées dans la vision par ordinateur offrent des opportunités pour améliorer cette classification, en particulier grâce à l'analyse d'images dermatoscopiques. Bien que des progrès significatifs aient été réalisés, des défis subsistent, notamment en ce qui concerne la validation clinique des modèles et la confidentialité des données. Malgré ces obstacles, l'intégration continue de ces technologies dans la pratique médicale promet d'améliorer les résultats pour les patients atteints de cancer de la peau.

L'objet du chapitre suivant sera donc de présenter une étude théorique approfondie sur le traitement d'imagerie médicale, en mettant en lumière l'importance de la classification des images pour optimiser les processus de diagnostic et de traitement.

TRAITEMENT DES IMAGES MEDICALES

Dans ce chapitre, nous traitons brièvement des principales caractéristiques des images médicales traitées au sein de ce travail. Nous expliquons ensuite le problème de la classification d'images en général en définissant la nature et les objectifs de cette opération et en passant en revue de quelques modèles développés au cours de ces dernières années dans le cadre de la classification d'images.

II.1. Introduction

La santé est un domaine privilège des recherches scientifiques dans le monde sur le plan informatique, qui peut concerner l'analyse des images médicales pour l'assistance au diagnostic médical. L'imagerie médicale est devenue un outil indispensable pour l'aide à la décision. Pour cela, l'utilisation de nouvelles méthodes et techniques performantes est importante pour le traitement et l'interprétation des données. [26]

Traitement par ordinateur des images médicales peut non seulement aider les médecins dans le diagnostic des maladies, mais représente un outil puissant pour la thérapeutique et cela constitue un des intérêts clés du domaine de l'apprentissage machine (L'apprentissage automatique).L'apprentissage Profond est un nouveau volet du domaine de l'apprentissage automatique.

Dans cette étude, nous avons examiné comment les images médicales sont analysées, du moment où elles sont prises jusqu'à leur classification. Tout d'abord, nous avons parlé des différentes façons dont les images sont obtenues, comme avec les IRM et les scanners. Ensuite, nous avons discuté des étapes de prétraitement, où les images sont nettoyées et préparées pour l'analyse. En ce qui concerne la classification des images, nous avons exploré deux principales approches : supervisée et non supervisée. L'approche supervisée utilise des images déjà étiquetées pour entraîner des modèles à reconnaître des choses comme les organes ou les maladies. Les méthodes non supervisées, quant à elles, explorent les images pour découvrir des structures et des tendances sans avoir besoin d'étiquettes préalables.

L'utilisation de l'apprentissage machine dans ce processus est très importante. Les algorithmes d'apprentissage machine peuvent apprendre à reconnaître des choses complexes dans les images, ce qui peut aider les médecins à diagnostiquer plus rapidement et à traiter les patients de manière plus précise. Ils peuvent aussi aider à personnaliser les traitements en fonction des besoins de chaque patient, en analysant de grandes quantités de données médicales pour trouver des modèles spécifiques.

II.2. Les images médicales

II.2.1. Définition

On peut définir une image médicale comme la matérialisation sous forme d'images d'informations anatomiques ou fonctionnelles in vivo de parties (organes, tissus, cellules) du corps humain, ainsi que les données extraites ou dérivées de ces images. Ces images sont

obtenues pour répondre à un besoin grâce à des moyens techniques d'imagerie appropriés (en termes d'adéquation à la question posée, selon l'état de l'art), tout en minimisant les risques/coûts pour le patient. [27]

II.2.2. Objectif

L'image obtenue peut être traitée informatiquement pour obtenir :

- Une reconstruction tridimensionnelle d'un organe ou d'un tissu. [28]
- Un film montrant l'évolution ou les mouvements d'un organe au cours du temps. [29]
- Une imagerie quantitative qui représente les valeurs mesurées pour certains paramètres biologiques dans un volume donné.
- Une représentation multimodale recalant plusieurs données au sein d'un même document (contours de cœur, mobilité des parois,...).

II.2.3. Caractéristiques de l'image médicale

L'image est un ensemble structuré d'information caractérisé par les paramètres suivants :

II.2.3.1. Le pixel

Le pixel est une unité élémentaire qui constitue la base d'une image numérique. Il concrétise un point (x, y) du plan de l'image. Un pixel représente le niveau de gris ou de couleur prélevé de l'image réelle. La différence entre image monochrome et image couleur réside dans la quantité d'informations contenues dans chaque pixel.

II.2.3.2. Dimension et Résolution

La dimension, c'est la taille de l'image et elle correspond au nombre total de pixels dans celle-ci. Par contre, la résolution est la clarté ou la finesse de détails atteinte par un moniteur ou une imprimante dans la production d'images. On utilise aussi le mot résolution pour désigner le nombre de pixels par pouce (1 pouce = 2.54 centimètres). Elle est exprimée en "PPP" (points par pouce).

II.2.3.3. Voisinage

Le voisinage d'un pixel est représenté par l'ensemble des pixels qui entourent ce même pixel. Cet ensemble de voisinage définit la notion de l'assiette. La division du plan de l'image en forme rectangulaire ou hexagonale permet l'exploitation de la notion de voisinage.

II.2.3.4. Luminance

C'est une grandeur photométrique qui dépend de la sensation visuelle et donc de la sensibilité de l'œil, Elle représente le degré de luminosité des points de l'image, elle peut être définie aussi par le mot brillance qui correspond à l'éclat d'un objet.

II.2.3.5. Bruit

Un bruit est un défaut parasite qui subit des dégradations dans la qualité de l'image, il représente la variation de l'intensité d'un pixel par rapport à ses voisins. Parmi ces défauts on a : la poussière, petits nuages, faible intensité électrique...etc.

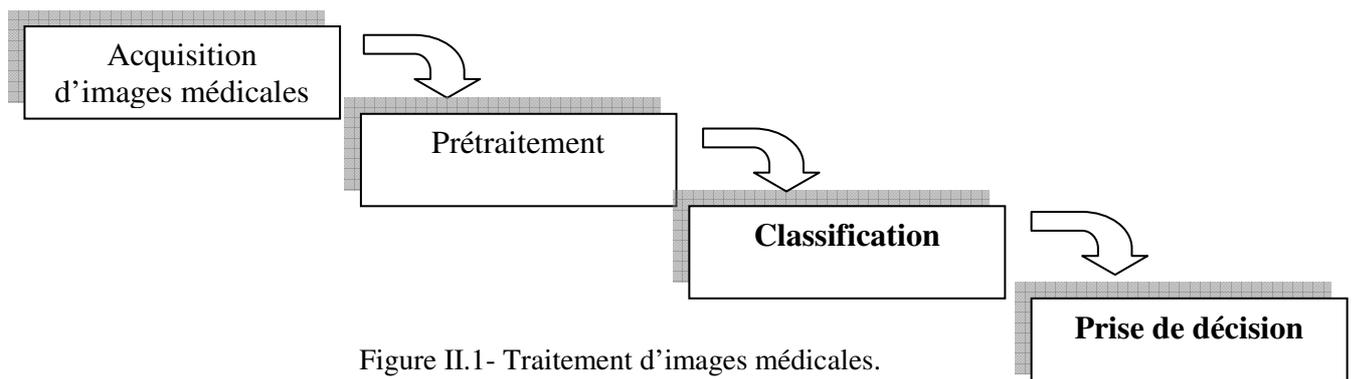
II.2.3.6. Contour

Dans une image numérique, le contour désigne la frontière entre chaque objet de l'image, et la détection de ce contour a pour but de repérer les points de l'image numérique qui correspondent à un changement brutal de l'intensité lumineuse, et ça cause une élimination d'information et une réduction de la qualité de l'image.

II.3. Traitement des images médicales

Les images médicales à l'état brut sont difficilement exploitables. Afin d'améliorer leur qualité, différents traitements numériques ont été mis au point tel que :

- Le prétraitement comprend diverses opérations visant à améliorer la qualité de l'image et à faciliter sa classification. Ces opérations sont principalement l'amélioration du contraste, la modification de l'histogramme et la réduction du bruit.
- La classification des images médicales émerge comme une solution cruciale pour organiser, analyser et extraire des informations pertinentes à partir de ces ensembles de données complexes. Cette exploration approfondie des méthodes de classification, des enjeux et des applications dans le domaine de l'imagerie médicale vise à fournir un aperçu complet des progrès réalisés ainsi que des défis à relever.



II.3.1. Acquisition de l'image

C'est la conversion de l'image analogique en image numérique selon le processus de numérisation. Les dispositifs utilisés pour l'acquisition des images sont principalement : Les appareils photo numériques, scanners, caméras et les cartes d'acquisition.

L'acquisition d'images médicales est une étape cruciale dans le processus de diagnostic et de suivi des patients. Cette procédure utilise une variété de modalités telles que l'imagerie par résonance magnétique (IRM), la tomodensitométrie (TDM), la radiographie et l'échographie, chacune offrant des informations uniques sur les structures anatomiques et les processus pathologiques.

II.3.1.1. Imagerie par Résonance Magnétique (IRM)

L'IRM produit des images hautement détaillées des tissus mous en utilisant un champ magnétique et des ondes radio. Elle est particulièrement adaptée pour visualiser le cerveau, la moelle épinière, les articulations et les organes internes. [30]

II.3.1.2. Image par rayons X

Les rayons x sont des vibrations de l'électromagnétique avec des radiations tout comme les rayons lumineux. Ces radiations ont des propriétés spéciales elles ne sont pas complètement arrêtées par la matière qu'elles rencontrent certaines d'entre elles la traversent : d'autres s'y amortissent et en s'amortissant libèrent une quantité d'énergie susceptible de déterminer des actions électrique physique ou chimique. [26]

L'utilisation de rayons X est d'usage courant. Ces rayonnements, comme les rayons gamma sont ionisants et donc dangereux. En particulier, l'irradiation d'une cellule en phase de mitose peut provoquer une mutation de l'ADN et peut provoquer l'apparition d'un cancer à terme. Toutefois, grâce aux mesures de radioprotection, le risque inhérent aux examens X est limité au maximum. [26]

II.3.1.2.1. Tomodensitométrie (TDM)

La TDM utilise des rayons X pour créer des images en coupes transversales du corps. Elle est idéale pour visualiser les structures osseuses, les tumeurs et les saignements internes, offrant une résolution élevée et des images détaillées. [30]

II.3.1.2.2. Radiographie

La radiographie utilise des rayons X pour produire des images des os et des tissus mous. Elle est couramment utilisée pour diagnostiquer les fractures, les infections pulmonaires et les maladies cardiaques. [30]

II.3.1.3. Image ultra son

L'échographie utilise des ondes sonores pour créer des images en temps réel des organes internes et des tissus. Elle est sûre, non invasive et largement utilisée pour examiner les organes abdominaux, le cœur, les vaisseaux sanguins et les fœtus pendant la grossesse.

La sélection de la modalité appropriée dépend souvent de la condition médicale suspectée, de la région anatomique à étudier et des besoins spécifiques du patient. Chaque modalité présente des avantages et des limitations uniques, et le choix de la technique d'imagerie optimale repose sur une évaluation approfondie des besoins diagnostiques et cliniques du patient. [30]

Le choix judicieux de la modalité d'imagerie contribue à garantir des résultats précis et fiables, tout en minimisant l'exposition aux rayonnements et en optimisant le confort du patient. En intégrant ces différentes modalités dans le processus de diagnostic, les professionnels de la santé peuvent obtenir une vision complète de l'état de santé du patient et fournir des soins adaptés et personnalisés. [30]

II.3.2. Prétraitement des images médicales

Le prétraitement des images médicales constitue une étape fondamentale visant à améliorer la qualité et la fiabilité des données avant leur analyse et leur interprétation. Cette phase englobe une série de processus visant à corriger les imperfections et à optimiser les images pour une utilisation ultérieure dans les applications médicales.

II.3.2.1. Correction des artéfacts

La correction des artéfacts est essentielle pour éliminer les anomalies introduites par les mouvements du patient ou les défauts de l'équipement. Ces artéfacts peuvent entraîner des distorsions ou des irrégularités dans les images, compromettant ainsi leur utilité pour le diagnostic. Les techniques de correction des artéfacts visent à restaurer la qualité originale de l'image en éliminant les erreurs ou en les atténuant. [31]

II.3.2.2. Normalisation des intensités

La normalisation des intensités est nécessaire pour garantir une comparaison cohérente entre différentes images. Cette étape implique l'ajustement des valeurs de pixels pour égaliser les niveaux de luminosité et de contraste. Cela permet d'assurer une cohérence dans les mesures et les analyses effectuées sur les images, indépendamment des variations dans l'éclairage ou les paramètres de capture. [31]

II.3.2.3. Réduction du bruit

La réduction du bruit est cruciale pour améliorer la clarté et la précision des structures anatomiques dans les images. Le bruit peut provenir de diverses sources, telles que les capteurs d'imagerie ou les conditions environnementales. Les techniques de réduction du bruit visent à atténuer ces perturbations tout en préservant les détails et les caractéristiques importantes de l'image.

II.3.3. Importance du prétraitement

Ces techniques de prétraitement sont essentielles pour maximiser l'efficacité des algorithmes de classification et garantir des résultats fiables et reproductibles en imagerie médicale. En éliminant les artefacts, en normalisant les intensités, en réduisant le bruit et en segmentant les régions d'intérêt, le prétraitement permet d'améliorer la qualité des données et de faciliter les analyses ultérieures.

Un prétraitement efficace contribue à une interprétation plus précise des images, ce qui est crucial pour le diagnostic médical et la prise de décision clinique. En combinant des techniques de prétraitement avancées avec des algorithmes de classification sophistiqués, il est possible d'exploiter pleinement le potentiel des images médicales pour améliorer les soins aux patients et les résultats cliniques. [31]

II.3.3.1. Les histogrammes

II.3.3.1.1. Principe

Un histogramme est une courbe statistique indiquant la répartition des pixels selon leur valeur d'intensité lumineuse. L'histogramme des niveaux de gris ou des couleurs d'une image est une fonction qui donne la fréquence d'apparition de chaque niveau de gris (ou couleur) dans l'image.

L'histogramme est très utile pour contrôler l'exposition d'une image. i) A l'acquisition, il permet de contrôler et affiner les réglages de prise de vue. ii) Pour le traitement, il peut être utilisé pour améliorer la qualité d'une image (Rehaussement d'images) en introduisant quelques modifications pour pouvoir extraire les informations utiles de celle-ci. Les attributs qui en sont souvent extraits de ces histogrammes pour discriminer les différentes classes sont : 1) La médiane, qui partitionne l'histogramme en deux parties d'égale population, 2) Le mode, qui correspond au maximum de l'histogramme et 3) L'intervalle interquartile, qui est une caractéristique de dispersion autour de la médiane. iii) en utilisant l'histogramme, on peut faire apparaître les détails et les nuances acquises par le capteur et présentes dans le fichier, mais non visibles à l'œil. Tout comme pour les statistiques d'images, l'inconvénient majeur des histogrammes est qu'ils n'exploitent que l'information de couleur et négligent les relations spatiales entre les pixels. Il est donc nécessaire de considérer des attributs statistiques d'ordre supérieur pour une analyse de texture plus efficace. La figure II.2 montre un exemple d'un histogramme d'une image de cancer de la peau en couleur.

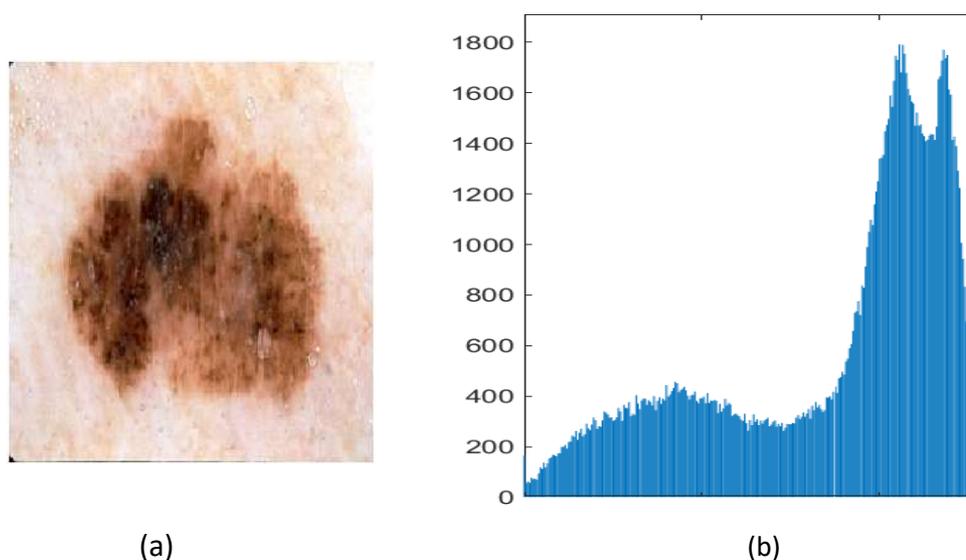


Figure II.2 - Histogramme d'une image de cancer de la peau en couleur.

a) Image originale, b) histogramme de l'image originale.

On modifie généralement l'histogramme pour diminuer l'erreur de quantification pour comparer deux images obtenues sous des éclairages différents, ou encore pour mesurer certaines propriétés sur une image [32]. Il permet de donner un grand nombre d'informations sur la distribution des niveaux de gris et de voir entre quelles bornes est répartie la majorité des niveaux de gris dans les cas d'une image trop claire ou d'une image trop foncée.

II.3.3.1.2. Modifications d'histogrammes

Pour modifier les caractéristiques de l'image (accentuer les contrastes en général), une approche générale consiste à appliquer une fonction qui associe à chaque valeur d'intensité dans l'image une nouvelle valeur. Cette fonction va modifier l'histogramme de l'image [33]. L'idée est de modifier la répartition des niveaux pour obtenir un histogramme plat étendu à l'ensemble des valeurs possibles. Dans cette opération la dynamique originale $[\min, \max]$ est étalée à $[0, 255]$. On cherche à effectuer le même nombre de pixels à chaque niveau de gris ; c'est pourquoi on appelle cette opération équipopulation. L'effet obtenu permet de mieux séparer les valeurs les plus représentées dans l'image et de rapprocher les valeurs marginales. Cela a pour effet d'améliorer le contraste de l'image. Cette transformation peut aussi être appliquée pour réduire le nombre de niveaux pour la visualisation ; elle s'apparente alors à une classification puisqu'il s'agit de représenter plusieurs valeurs initiales par la même valeur finale.

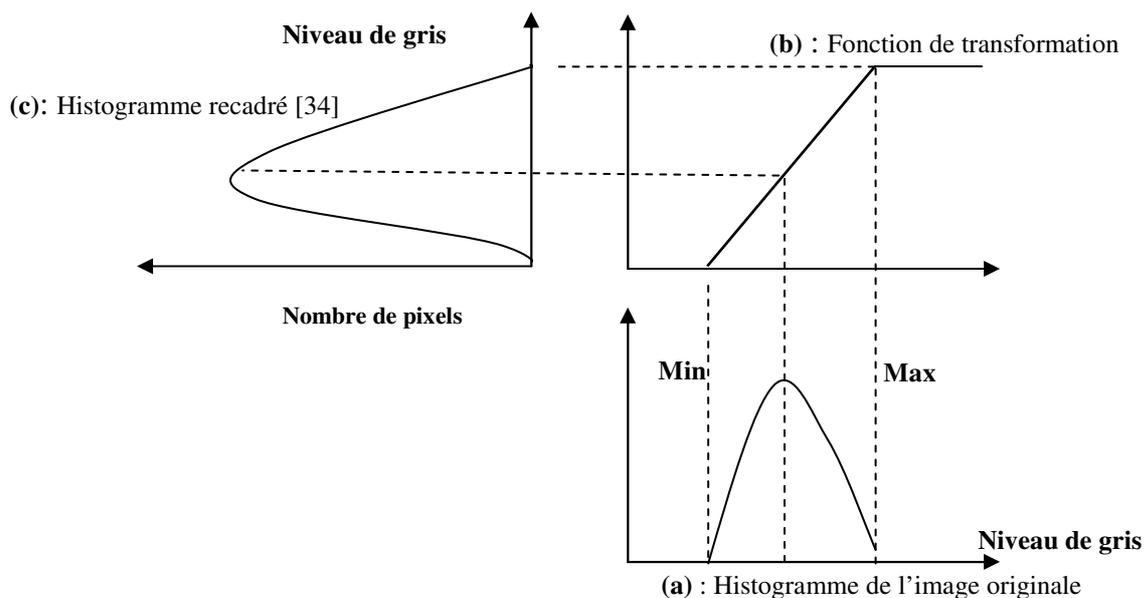


Figure II.3 - Principe de la modification d'histogramme.

Dans le cadre de cette recherche, on présente quelques exemples de l'amélioration de l'image par modification d'histogrammes.

II.3.3.1.2.1. Egalisation de l'histogramme

L'égalisation d'histogramme est un outil qui se voit souvent utile pour améliorer certaines images de mauvaise qualité (mauvais contraste, images trop sombres ou trop claires, mauvaise répartition des niveaux d'intensité, etc.) [34]. Elle consiste à appliquer une transformation sur chaque pixel de l'image, et donc d'obtenir une nouvelle image à partir

d'une opération indépendante sur chacun des pixels. Cette transformation est construite à partir de l'histogramme cumulé de l'image de départ.

L'égalisation est intéressante pour les images dont la totalité, ou seulement une partie, est de faible contraste (pixels d'intensité proche). La méthode est rapide, facile d'implémentation, et complètement automatique. L'égalisation d'histogrammes permet de mieux répartir les intensités sur l'ensemble de la plage de valeurs possibles, en étalant l'histogramme. La figure II.4 montre l'effet d'une égalisation de l'histogramme de l'image.

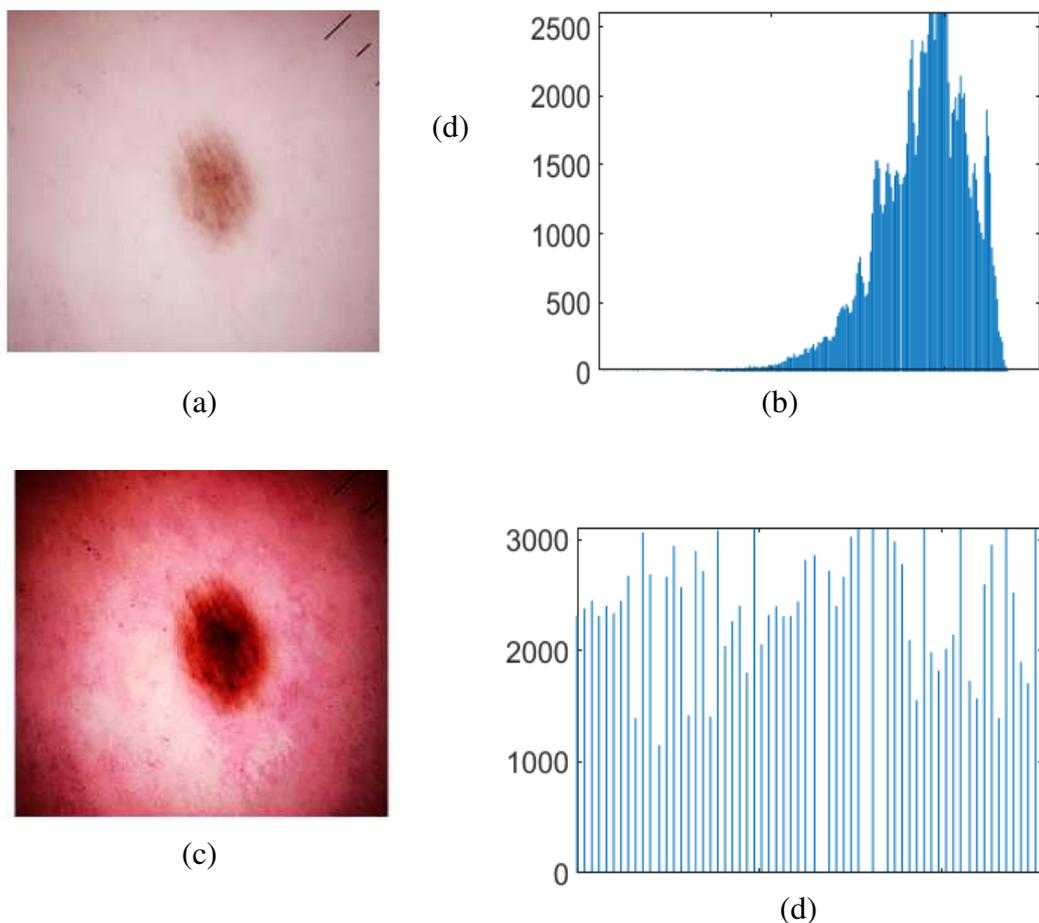


Figure II.4 - Image avant et après égalisation de l'histogramme.

a) Image originale, b) histogramme de l'image originale, c) image après égalisation et d) histogramme égalisé.

II.3.3.1.2.2. Étirement d'histogramme

Cette première transformation sur l'histogramme a pour objet l'augmentation du contraste d'une image. Pour cela, il convient d'augmenter sur l'histogramme l'intervalle $[a, b]$ de répartition des niveaux de gris de l'image d'entrée « I_e ». On parle alors d'étirement d'histogramme. Du point de vue de la transformation (voir figure II.5), un étirement maximal est réalisé dès lors que la répartition des niveaux de gris de l'image de sortie «

I_s » occupe l'intervalle maximal possible $[0, \text{Max}]$. [36] La figure suivante montre un exemple d'augmentation du contraste par étirement d'histogramme [35].

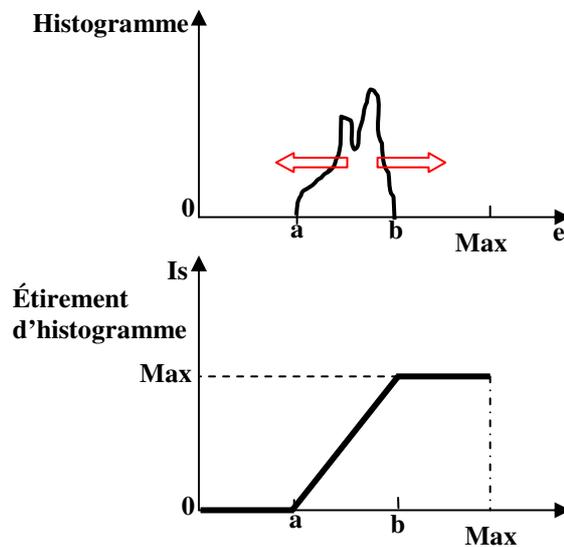


Figure II.5 - Augmentation du contraste par étirement d'histogramme [38].

La figure II.6 illustre l'étirement d'histogramme sur l'image [36]. L'image obtenue après étirement possède un meilleur contraste.

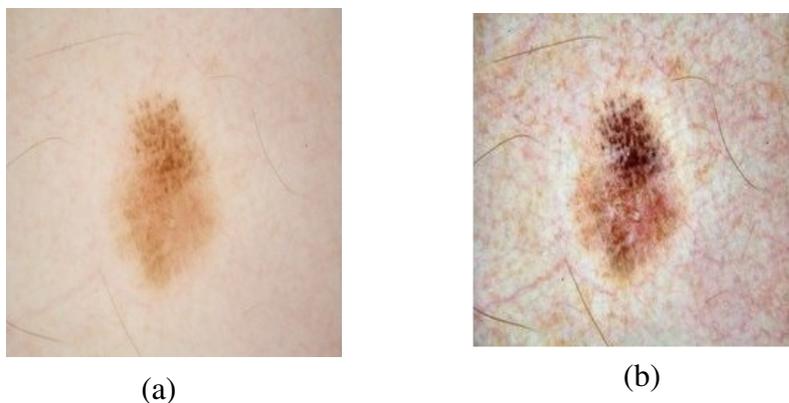


Figure II.6 - Augmentation du contraste d'une image par étirement d'histogramme

a) Image originale et b) image après étirement d'histogramme.

II.3.3.1.2.3. L'égalisation adaptative de l'histogramme

L'égalisation adaptative de l'histogramme consiste à appliquer sur chaque pixel ainsi que sa région contextuelle une égalisation d'histogramme. Cette région représente en effet les pixels voisins entourant le pixel traité [36]. La figure II.7 montre un exemple d'image améliorée par égalisation d'histogramme adaptative avec une implémentation sous Matlab.

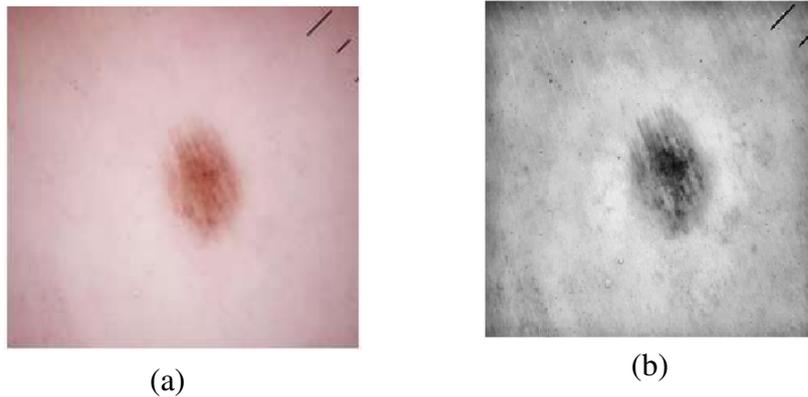


Figure II.7 - Image améliorée par égalisation d'histogramme adaptative

a) Image originale, b) image après étirement d'histogramme.

II.3.3.2. Les ondelettes

Les ondelettes permettent une représentation multi-résolution des images, ce qui est particulièrement adapté pour la compression d'images médicales volumiques, car elles peuvent réduire la redondance des données tout en maintenant la qualité des informations pertinentes pour le diagnostic. [28]



Figure II.8 - Image original et image après la méthode d'ondelette.

a) Image originale et b) images après l'amélioration

II.4. Classification des images médicales

Une étape cruciale pour l'organisation et l'interprétation des données médicales. La classification des images médicales revêt une importance capitale dans le domaine de l'imagerie médicale, offrant une méthodologie indispensable pour structurer, analyser et interpréter les vastes ensembles de données visuelles générés par les modalités d'imagerie modernes.

Cet aspect fondamental implique l'attribution de catégories ou de labels à chaque image en fonction de ses caractéristiques visuelles, anatomiques ou sémantiques. Il s'agit d'une étape cruciale pour découvrir des modèles, des tendances et des corrélations au sein des données d'imagerie, facilitant ainsi la prise de décision clinique et la planification thérapeutique. En outre, la classification des images médicales est essentielle pour l'élaboration et l'évaluation des algorithmes d'apprentissage machine, ouvrant la voie à l'automatisation et à l'amélioration des processus de diagnostic et de traitement.

En explorant les diverses méthodes et approches de classification, ainsi que leurs applications dans des contextes cliniques spécifiques, nous pouvons mieux appréhender l'impact de la classification des images médicales sur la pratique médicale moderne et identifier de nouvelles opportunités pour améliorer les soins de santé et les résultats des patients. [37]

II.4.1. Les méthodes de classification

La classification des images médicales permet d'identifier des structures anatomiques, des pathologies ou des anomalies dans des images. Pour ce faire, différentes méthodes de classification sont utilisées, parmi lesquelles les méthodes supervisées et non supervisées.

II.4.1.1. Les méthodes supervisées

Les avantages des méthodes supervisées résident dans leur capacité à fournir des résultats précis et fiables, en utilisant des données étiquetées pour entraîner les modèles. Cependant, elles nécessitent des ensembles de données étiquetées de grande qualité et représentativité pour garantir la performance et la généralisation des modèles en imagerie médicale.

Les méthodes supervisées de classification utilisent des ensembles de données étiquetées, où chaque image est associée à une catégorie prédéfinie. Ces méthodes exploitent des algorithmes d'apprentissage supervisés tels que les réseaux de neurones convolutionnels (CNN), les machines à vecteurs de support (SVM), Forêts d'arbres décisionnels (Random Forests), Réseaux de neurones classiques (ANN) et Réseaux de neurones récurrents (RNN). Les CNN, en particulier, sont bien adaptés à la classification d'images médicales en raison de leur capacité à apprendre des représentations hiérarchiques à partir des données brutes.

II.4.1.1.1. Réseaux de neurones convolutionnels (CNN)

Excellents pour extraire des caractéristiques d'images et classer précisément les données.

II.4.1.1.2. Machines à vecteurs de support (SVM)

Utiles pour classer les images en fonction de caractéristiques extraites des données.

II.4.1.1.3. Forêts d'arbres décisionnels (Random Forests)

Construisent un ensemble d'arbres de décision pour une classification précise.

II.4.1.1.4. Réseaux de neurones classiques (ANN)

Constitués de couches de neurones interconnectées pour la classification d'images.

II.4.1.1.5. Réseaux de neurones récurrents (RNN)

Utilisés pour l'analyse de séquences temporelles dans les images, comme les vidéos médicales.

II.4.1.2. Les méthodes non supervisées

Les méthodes de classification non supervisées regroupent les images en clusters sans utiliser d'étiquettes préalables. Ces approches, telles que le clustering K-means, l'analyse en composantes principales (PCA), et les algorithmes de clustering hiérarchique, explorent les structures sous-jacentes des données d'imagerie pour découvrir des motifs intrinsèques et des relations entre les images. Les méthodes non supervisées sont particulièrement utiles pour l'exploration et la découverte de nouvelles connaissances à partir de grands ensembles de données non annotées en imagerie médicale. Elles peuvent être utilisées pour segmenter automatiquement des régions d'intérêt dans les images, identifier des anomalies ou des sous-populations de patients, et pour la visualisation des données.

Cependant, les méthodes non supervisées présentent également des défis, notamment dans l'évaluation de la qualité des clusters obtenus et leur interprétation dans un contexte médical. De plus, elles nécessitent souvent un prétraitement minutieux des données pour réduire les dimensions et améliorer la qualité des clusters obtenus. [39]

II.4.1.2.1. Clustering K-means

Divise les données en clusters basés sur des similarités, sans besoin d'étiquettes préalables.

II.4.1.2.2. Analyse en composantes principales (PCA)

Réduit la dimensionnalité des données pour explorer les structures sous-jacentes et découvrir des motifs.

II.4.1.2.3. Clustering hiérarchique

Construit un arbre de clusters en fusionnant ou divisant progressivement en fonction de la similitude.

II.4.1.2.4. Décomposition en valeurs singulières (SVD)

Extract des caractéristiques importantes en décomposant la matrice d'images.

II.4.1.2.5. Algorithmes de mélange de gaussiennes (GMM)

Modélise la distribution des données pour identifier différents groupes.

II.4.1.2.6. Clustering spectral

Regroupe les images en utilisant les informations de similarité dans un espace spectral.

II.4.2. Classification des images et l'apprentissage machine

La classification des images médicales évolue rapidement grâce à l'utilisation croissante de techniques d'apprentissage machine, en particulier des modèles de réseaux de neurones profonds. Ces modèles sont conçus pour apprendre des représentations hautement discriminantes à partir de vastes ensembles de données d'imagerie, ce qui permet une classification précise et efficace des images médicales. L'avènement de l'apprentissage machine dans le domaine médical ouvre de nouvelles perspectives passionnantes pour l'automatisation des tâches de diagnostic, la détection de modèles pathologiques complexes et l'amélioration globale des soins aux patients. [40]

L'utilisation de l'apprentissage machine dans la classification des images médicales présente plusieurs avantages significatifs. Tout d'abord, ces techniques permettent une analyse automatisée et rapide des images médicales, réduisant ainsi le temps nécessaire au diagnostic. Cela peut être particulièrement bénéfique dans les situations d'urgence où des décisions rapides sont cruciales pour la prise en charge des patients. De plus, l'apprentissage machine permet une évaluation objective et reproductible des images, réduisant ainsi les erreurs potentielles dues à des variations interprétatives entre les radiologues ou les pathologistes. [40]

Un autre avantage majeur de l'apprentissage machine est sa capacité à détecter des modèles subtils ou complexes dans les images médicales, qui pourraient échapper à l'œil humain. Par exemple, les réseaux de neurones convolutifs profonds peuvent identifier des caractéristiques spécifiques dans les images qui sont liées à des maladies ou à des conditions médicales, même lorsque ces caractéristiques ne sont pas évidentes pour les praticiens. Cette capacité à détecter des informations subtiles peut conduire à des diagnostics plus précoces et à une meilleure prise en charge des patients. [40]

De plus, l'apprentissage machine permet une personnalisation des traitements en fonction des caractéristiques individuelles des patients. En analysant de vastes ensembles de données médicales, les algorithmes d'apprentissage machine peuvent identifier des tendances et des corrélations qui peuvent aider les médecins à recommander des traitements adaptés à chaque patient. Par exemple, ces techniques peuvent être utilisées pour prédire la réponse d'un patient à un certain traitement ou pour identifier les patients à risque de développer des complications. [40]

Cependant, malgré ses nombreux avantages, l'utilisation de l'apprentissage machine en classification d'images médicales pose également des défis. Tout d'abord, ces modèles dépendent fortement de la qualité et de la quantité des données d'entraînement. Un ensemble de données insuffisant ou biaisé peut entraîner des résultats incohérents ou incorrects. De plus, l'interprétation des décisions prises par les modèles d'apprentissage machine peut être difficile, ce qui peut limiter leur adoption par les praticiens médicaux. Enfin, il existe des préoccupations éthiques et de confidentialité concernant l'utilisation des données médicales pour l'entraînement des modèles, ainsi que des questions de responsabilité en cas d'erreur ou de mauvaise interprétation des résultats par les algorithmes. [40]

II.5. Conclusion

La classification des images médicales est un domaine essentiel et en pleine expansion, combinant les avancées de l'imagerie médicale. Ce chapitre a présenté les principales étapes du traitement des images médicales, y compris l'acquisition, le prétraitement et le classement, ainsi que les méthodes de classification supervisées et non supervisées. L'intégration des techniques de l'intelligence artificielle dans ce processus a démontré son potentiel pour améliorer la précision et l'efficacité des diagnostics médicaux. Bien que des défis subsistent, notamment en termes de gestion des données et de standardisation des techniques, les progrès continus dans ce domaine promettent de transformer la pratique clinique et d'améliorer les résultats pour les patients.

L'objet du chapitre suivant sera donc de présenter une étude approfondie sur les appuis majeurs de l'intelligence artificielle.

LES APPUIS MAJEURS DE L'INTELLIGENCE ARTIFICIELLE

Dans ce chapitre, nous avons abordé diverses notions clés telles que l'intelligence artificielle (IA) et les différents types d'apprentissage automatique, y compris les réseaux de neurones. Ensuite, nous avons exploré en détail l'apprentissage profond, ses méthodes distinctes ainsi que quelques domaines d'application. Enfin, une attention particulière a été accordée à la méthode des réseaux de neurones convolutifs (CNN), avec une analyse détaillée de son architecture, de ses différentes couches, ainsi que de ses avantages et inconvénients.

III.1. Introduction

L'intelligence artificielle englobe une vaste gamme de domaines intellectuels, ce qui rend sa définition plus complexe que cela. En effet, elle est également définie comme un style de programmation où les programmes traitent les données selon des règles pour atteindre des objectifs. [18]

L'intelligence artificielle consiste à étudier les systèmes qui agissent de manière intelligente, perceptible par tout observateur. Cependant, cette définition ne capture pas entièrement la portée de l'intelligence artificielle. Souvent, les techniques d'IA sont utilisées pour résoudre des problèmes relativement simples ou des problèmes complexes à l'intérieur de systèmes plus vastes. Une définition plus complète de l'intelligence artificielle pourrait être formulée comme suit : l'utilisation de méthodes inspirées par le comportement intelligent des êtres humains et d'autres animaux pour résoudre des problèmes complexes. [18]

Les méthodes de traitement d'images et les techniques d'apprentissage classiques ont prouvé 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 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.

Beaucoup d'entre nous sont incapables de faire la distinction entre intelligence artificielle (IA), apprentissage automatique (ML) et apprentissage approfondi (DL), mais si les trois termes sont souvent utilisés de manière interchangeable, ils ne font pas référence aux mêmes choses. Voici une figure qui tente de visualiser la distinction ou bien la relation entre eux (figure III.1):

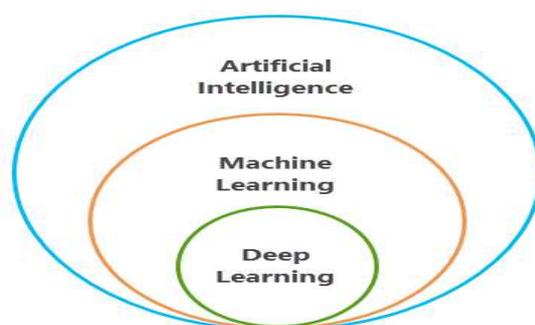


Figure III.1 - Affiliation de deep learning (relation entre I.A. et M.L. et deep learning)

Les algorithmes de machine learning (ML) sont généralement conçus pour traiter des données structurées, tandis que les réseaux d'apprentissage profond reposent sur des architectures composées de multiples couches de réseaux de neurones artificiels (RNA). Une différence notable entre les modèles de deep learning (DL) et ceux de machine learning (ML) réside dans leur architecture, les modèles DL étant souvent plus complexes et profonds que les modèles ML. Alors que le deep learning se concentre principalement sur l'utilisation de réseaux de neurones, le machine learning offre une gamme plus large d'approches pour la conception de modèles, dont les réseaux de neurones ne représentent qu'une option parmi d'autres. En considérant le deep learning comme une évolution naturelle du machine learning, il vise à autonomiser les machines pour prendre des décisions précises sans intervention humaine, marquant ainsi une avancée significative dans le domaine de l'intelligence artificielle. [21]

Dans cette section, nous allons explorer tous les aspects liés aux réseaux neuronaux tels que L'apprentissage automatique, l'apprentissage en profondeur et les réseaux de neurones convolutifs.

III.2. L'apprentissage automatique & l'apprentissage profond

Le machine learning et le deep learning se distinguent par leur approche et leur capacité à traiter des données. Le machine learning englobe diverses techniques permettant aux machines d'apprendre à partir de données, tandis que le deep learning, une sous-catégorie de la machine learning, utilise des réseaux de neurones artificiels profonds pour extraire des représentations complexes des données.

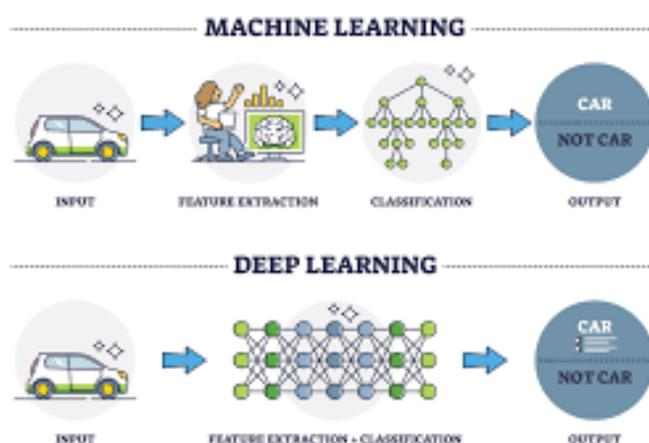


Figure III.2 - Le machine learning et le deep learning

III.2.1. L'apprentissage automatique (Machine Learning (ML))

Le machine learning, un domaine de l'intelligence artificielle, se concentre sur la conception d'algorithmes permettant à une machine d'apprendre à partir de données collectées précédemment. Le terme "machine learning" a été introduit en 1959 par Arthur Samuel, qui l'a défini comme la capacité d'une machine à apprendre automatiquement à partir de données, à améliorer ses performances par le biais d'un processus d'apprentissage, et à fournir ensuite des résultats qui n'ont pas été explicitement programmés. [19]

III.2.1.1. Les types de l'apprentissage automatique

Les apprentissages automatiques peuvent se catégoriser selon le type d'apprentissage qu'ils emploient : l'apprentissage supervisé, l'apprentissage non supervisé, l'apprentissage semi-supervisé, l'apprentissage partiellement et l'apprentissage par renforcement.

III.2.1.1.1. L'apprentissage supervisé

Si les classes sont prédéterminées et les exemples connus, le système apprend à classer selon un modèle de classement ; on parle alors d'apprentissage supervisé (ou d'analyse discriminante). Un expert doit préalablement correctement étiqueter des exemples. L'apprenant peut alors trouver ou approximer la fonction qui permet d'affecter la bonne « étiquette » à ces exemples. Parfois il est préférable d'associer une donnée non pas à une classe unique, mais une probabilité d'appartenance à chacune des classes prédéterminées (on parle alors d'apprentissage supervisé probabiliste). L'analyse discriminante linéaire ou les SVM sont des exemples typiques. [20]

III.2.1.1.2. L'apprentissage non supervisé

Quand le système ou l'opérateur ne dispose que d'exemples, mais non d'étiquettes, et que le nombre de classes et leur nature n'ont pas été prédéterminés, on parle d'apprentissage non supervisé. Aucun expert n'est disponible ni requis. L'algorithme doit découvrir par lui-même la structure plus ou moins cachée des données. Le système doit ici dans l'espace de description cibler les données selon leurs attributs disponibles, pour les classer en groupe homogènes d'exemples. La similarité est généralement calculée selon la fonction de distance entre paires d'exemples. C'est ensuite à l'opérateur d'associer ou déduire du sens pour chaque groupe. Divers outils mathématiques et logiciels peuvent l'aider. On parle aussi d'analyse des données en régression. Si l'approche est probabiliste (c'est à dire que chaque exemple au lieu

d'être classé dans une seule classe est associé aux probabilités d'appartenir à chacune des classes), on parle alors de « soft clustering » (par opposition au « hard clustering »). [20]

III.2.1.1.3. L'apprentissage semi-supervisé

Effectué de manière probabiliste ou non, il vise à faire apparaître la distribution sous-jacente des « exemples » dans leur espace de description. Il est mis en œuvre quand des données (ou « étiquettes ») manquent... Le modèle doit utiliser des exemples non-étiquetés pouvant néanmoins renseigner. L'apprentissage partiellement supervisé (probabiliste ou non) quand l'étiquetage des données est partiel. C'est le cas quand un modèle énonce qu'une donnée n'appartient pas à une classe A, mais peut-être à une classe B ou C (A, B et C et 3 maladies par exemple évoquées dans le cadre d'un diagnostic différentiel). [20]

III.2.1.1.4. L'apprentissage par renforcement

L'algorithme apprend un comportement étant donné une observation. L'action de l'algorithme sur l'environnement produit une valeur de retour qui guide l'algorithme. [20]

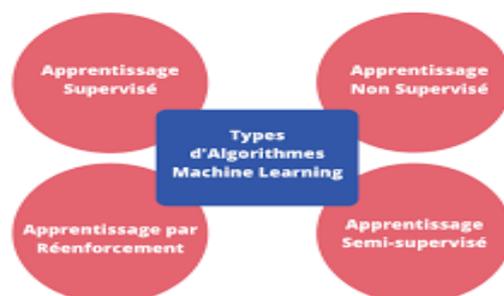


Figure III.3 - Les types de l'apprentissage automatique. [20]

III.2.2. L'apprentissage profond (Deep learning)

L'apprentissage profond « deep learning » est un ensemble de techniques d'apprentissage automatique qui a permis des avancées importantes en intelligence artificielle dans les dernières années. L'apprentissage profond est basé sur ce qui a été appelé, par analogie, des « réseaux de neurones artificiels », composés de milliers d'unités (les « neurones ») qui effectuent chacune de petites opérations simples. Les résultats d'une première couche de « neurones » servent d'entrée au calcul d'une deuxième couche et ainsi de suite. Les progrès de l'apprentissage profond ont été possibles notamment grâce à l'augmentation de la puissance des ordinateurs et au développement de grandes bases de données (« big data »). [21]

III.2.2.1. Les algorithmes de l'apprentissage profond

En apprentissage profond, on utilise différents types d'algorithmes. Chaque algorithme a ses propres spécificités et applications.

III.2.2.1.1. Réseaux neuronaux convolutifs (CNN)

Également appelés ConvNets, les CNN sont constitués d'une multitude de couches chargées de traiter et d'extraire les caractéristiques des données. De manière spécifique, les réseaux neuronaux convolutifs sont utilisés pour l'analyse et la détection d'objets. Ils peuvent donc servir par exemple à reconnaître des images satellites, traiter des images médicales, détecter des anomalies ou prédire des séries chronologiques. [22]

III.2.2.1.2. Réseaux neuronaux récurrents (RNN)

Les réseaux neuronaux récurrents possèdent des connexions qui constituent des cycles dirigés. Cela permet aux sorties du LSTM d'être exploitées comme entrées au niveau de la phase actuelle. La sortie du LSTM se transforme en une entrée pour la phase actuelle. Elle peut donc mémoriser les entrées précédentes à l'aide de sa mémoire interne. Dans la pratique, les RNN sont utilisés pour le sous-titrage d'images, le traitement du langage naturel et la traduction automatique. [22]

III.2.2.1.3. Réseaux de fonction de base radiale (RBFN)

Ces algorithmes sont des réseaux neuronaux feed forward assez particuliers. Ils exploitent des fonctions de base radiales en tant que fonctions d'activation. Ils sont constitués d'une couche d'entrée, d'une couche cachée et d'une couche de sortie. Généralement, les RBFN sont utilisés dans la classification, la prédiction des séries temporelles et la régression linéaire. [22]

III.2.2.1.4. Réseaux de mémoire à long et court terme (LSTM)

Les LSTM sont des dérivés de RNN. Ils peuvent apprendre et mémoriser des dépendances sur une longue durée. Les LSTM conservent ainsi les informations mémorisées sur le long terme. Ils sont particulièrement utiles pour prédire des séries chronologiques, car ils se rappellent des entrées précédentes. Outre ce cas d'utilisation, les LSTM sont également utilisés pour composer des notes de musique et reconnaître des voix. [22]

III.2.2.1.5. Réseaux adversariaux génératifs (GAN)

Les GAN créent de nouvelles instances de données qui s'apparentent aux données d'apprentissage profond. Ils possèdent deux principaux composants : un générateur et un discriminateur. Si le générateur apprend à produire des informations erronées, le discriminateur, quant à lui, apprend à exploiter ces fausses informations. Les GAN sont généralement utilisés par les créateurs de jeux vidéo pour améliorer les textures 2D. [22]

III.2.2.1.6. Machines de Boltzmann restreintes (RBM)

C'est le professeur Geoffrey Hinton qui a développé cet algorithme. En d'autres termes, les machines de Boltzmann restreintes sont des réseaux neuronaux stochastiques constitués de deux couches : unités visibles et unités cachées. Ces réseaux artificiels sont capables d'apprendre en partant d'une distribution de probabilité sur un ensemble d'entrées. Néanmoins, il est important de souligner que la liste d'algorithmes présentés ci-dessus n'est pas exhaustive. Il en existe en effet d'autres types comme : les auto-encodeurs et les perceptrons multicouches (MLP). [22]

III.2.2.2. Les application de l'apprentissage profond

Ces techniques se développent dans le domaine de l'informatique appliquée aux NTIC (reconnaissance visuelle - par exemple d'un panneau de signalisation par un robot ou une voiture autonome et vocale notamment) à la robotique, à la bioinformatique, la reconnaissance ou comparaison de formes, la sécurité, la santé, etc. La pédagogie assistée par l'informatique, et plus généralement à l'intelligence artificielle. L'apprentissage profond peut par exemple permettre à un ordinateur de mieux reconnaître des objets hautement déformables et/ou analyser par exemple les émotions révélées par un visage photographié ou filmé, ou analyser les mouvements et positions des doigts d'une main, ce qui peut être utile pour traduire le langage des signes, améliorer le positionnement automatique d'une caméra, etc. Elles sont utilisées pour certaines formes d'aide au diagnostic médical (ex. : reconnaissance automatique d'un cancer en imagerie médicale). [21]

III.2.3. Différences entre machine learning & deep learning

Machine learning et deep learning sont deux méthodes de l'intelligence artificielle (IA) pour apprendre à partir de données, mais elles varient dans leur façon d'apprendre et de traiter l'information.

III.2.3.1. Données et complexité des tâches

- machine learning: plus adapté à des tâches moins complexes et nécessitant moins de données.
- deep learning: efficace pour des tâches complexes et des données massives.

III.2.3.2. Ingénierie des caractéristiques

- machine learning: nécessite souvent une ingénierie des caractéristiques manuelle.
- deep learning: peut apprendre automatiquement des représentations des données, réduisant le besoin d'ingénierie des caractéristiques.

III.2.3.3. Interprétabilité

- machine learning: souvent plus facile à interpréter, car les modèles peuvent être basés sur des règles explicites.
- deep learning: Les modèles peuvent être plus opaques en raison de la complexité de leurs réseaux neuronaux.

III.2.3.4. Puissance de calcul

- machine learning: nécessite moins de ressources de calcul.
- deep learning: nécessite souvent des ressources de calcul plus importantes, comme des GPU, en raison de la complexité de ses réseaux neuronaux.

III.3. Les réseaux neurones

Les réseaux de neurones (Neural Networks) sont l'un des algorithmes d'apprentissage automatique les plus populaires à l'heure actuelle. Au fil du temps, il a été prouvé de manière décisive que les réseaux de neurones surpassent les autres algorithmes en termes de précision et de rapidité. Avec diverses variantes telles que réseaux de neurones convolutifs (CNN), réseaux de neurones récurrents (RNN), auto-encodeurs, etc..., les réseaux de neurones deviennent peu à peu pour les scientifiques où les praticiens de l'apprentissage automatique, ce que la régression linéaire était pour les statisticiens. [23]

III.3.1. Les neurones biologiques

Un neurone (cellule nerveuse) est une cellule qui transporte des impulsions électriques, où elles sont connectées les unes aux autres. Ils ne se touchent pas et forment à la place de

minuscules espaces appelés synapses. Ces lacunes peuvent être des synapses chimiques ou des synapses électriques et transmettre le signal d'un neurone à l'autre. [24]

III.3.2. Les réseaux de neurones artificiels (RNA)

Les réseaux de neurones artificiels sont des modèles informatiques inspirés du fonctionnement du cerveau humain. Chaque neurone dans un réseau de neurones calcule une valeur de sortie en appliquant une fonction spécifique aux valeurs d'entrée reçues. Cette fonction est déterminée par un vecteur de poids et un biais. L'apprentissage dans ces réseaux implique l'ajustement itératif de ces poids et biais (Voir figure III.4). Contrairement aux réseaux entièrement connectés, les réseaux de neurones convolutifs (CNN) sont une forme régularisée de réseau de neurones qui apprennent l'ingénierie des caractéristiques par l'optimisation des filtres. Les CNN utilisent des filtres pour extraire des caractéristiques des entrées, ce qui les rend efficaces pour des tâches telles que la reconnaissance d'images, la segmentation d'images, l'analyse d'images médicales, le traitement du langage naturel, etc. [25]

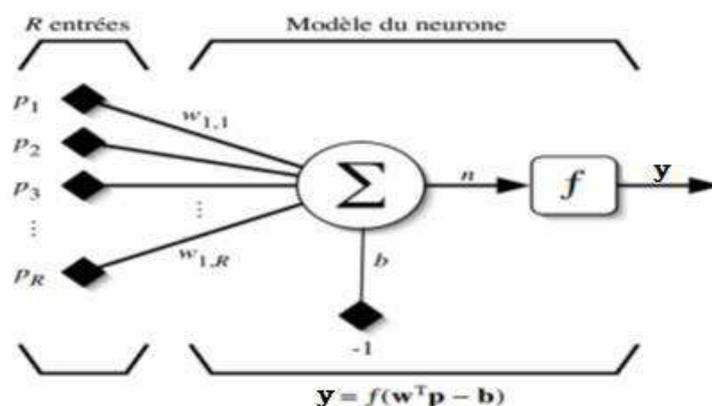


Figure III.4 - Modèle d'un neurone artificiel. [28]

III.3.3. Les réseaux de neurones convolutifs

Les réseaux de neurones convolutifs (CNN) sont une forme spécifique de réseau de neurones, souvent utilisée dans la vision par ordinateur pour traiter des données telles que des images. Le principe de CNN est d'obtenir des entrées (images) dans les rangs supérieurs et de les fusionner en entrées complexes dans les rangs inférieurs [31]. Nous présentons sur la figure III.5 l'architecture standard d'un réseau de neurone convolutif.

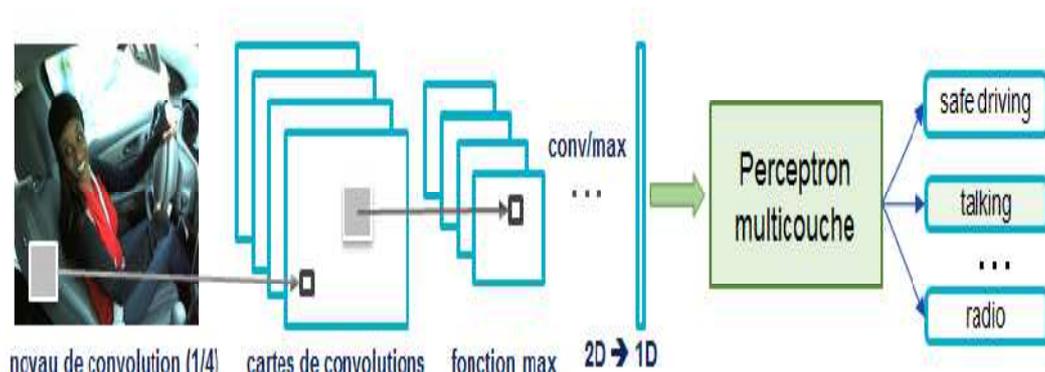


Figure III.5 - Architecture standard d'un réseau de neurone convolutif. [28]

III.3.3. 1. Les principales couches du CNN

Le réseau neuronal « CNN » est une technique d'apprentissage profond composée d'un groupe de plusieurs couches et d'un champ local, utilisant la communication locale et le partage du poids dans le but d'améliorer l'efficacité et les performances. En effet, la structure profonde aide les réseaux à apprendre de nombreuses caractéristiques ou descripteurs complexes qu'aucun réseau simple ne peut apprendre. Nous mentionnons sur la figure III.6 les principales couches de traitement d'un CNN.

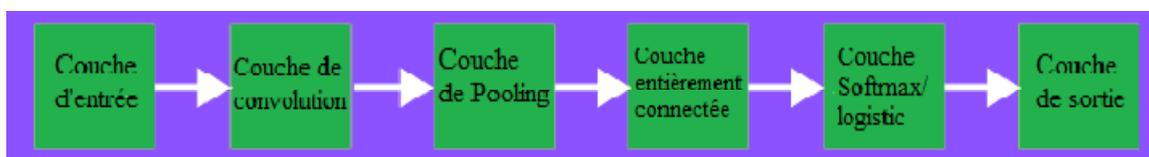


Figure III.6 - Les principales couches de traitement d'un CNN.

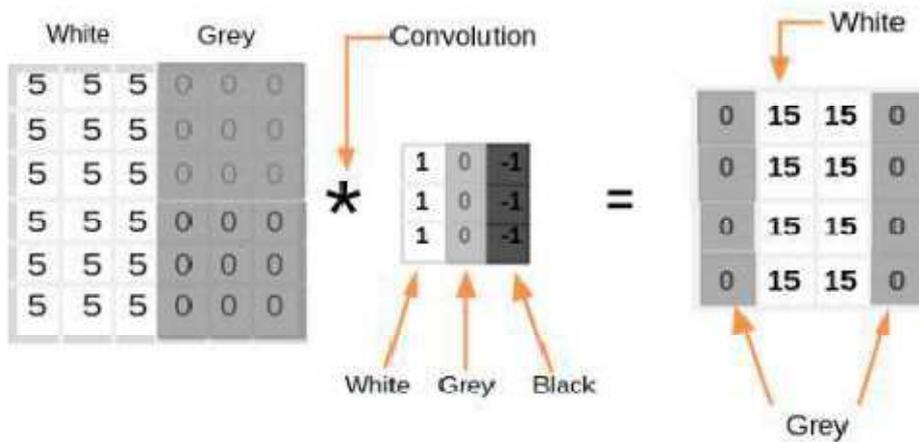
III.3.3.1.1. Couche d'entrée

Les CNN doivent être alimentés par des données décrivant l'image. Les données d'image sont généralement représentées par une matrice tridimensionnelle, qui est souvent remodelée en une seule colonne pour former une représentation vectorielle.

III.3.3.1.2. Couche de convolution (CONV.)

La couche de convolution est la première couche d'un CNN et est essentielle pour détecter des caractéristiques dans les images en appliquant des filtres. Elle utilise des filtres pour balayer l'image et calculer la convolution entre les filtres et les différentes parties de l'image, produisant des cartes de caractéristiques. Les hyper-paramètres clés de cette couche incluent la profondeur, le pas (contrôle du chevauchement des filtres) et le zéro padding

(ajout de zéros à la frontière de l'image). Nous exposons sur la figure III.7 un exemple de principe du filtre convolutionnel.



III.7 - Exemple de principe du filtre convolutionnel. [29]

III.3.3.1.3. Couche de pooling (POOL)

La couche de pooling est souvent placée après les couches de convolution pour réduire la dimensionnalité des cartes de caractéristiques tout en préservant les informations essentielles. L'opération de pooling consiste à réduire la taille des cartes de caractéristiques en appliquant une fonction d'agrégation, comme le max pooling (ou le average pooling). Nous exposons sur la Figure III.8 un exemple du processus max pooling.

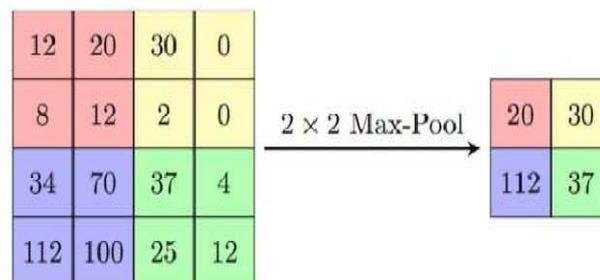


Figure III.8 - Exemple d'une opération de Max pooling de taille 2 x 2.

L'échantillonnage a comme but de réduire partiellement la taille des données d'entrée tout en permettant de [32] :

- La gestion facile ainsi que la réduction de la représentation des entrées.
- La réduction de la taille des données pour ne pas nécessiter une grande puissance de calcul lors du traitement des données.
- Le maintien de l'efficacité du processus d'apprentissage en extrayant uniquement les caractéristiques nécessaires.

III.3.3.1.4. Couche de correction ReLU

Elle est souvent utilisée après la couche convolutive et se présente sous la forme d'une couche séparée [32]. Généralement, la correction ReLU est préférable, vu le fait qu'il en résulte un réseau neuronal plusieurs fois plus rapide en effet, nous appliquons la fonction ReLU sur chaque pixel de l'image après convolution où l'ultime but consiste à remplacer chaque valeur négative par un 0 comme exposé sur la figure III.9.

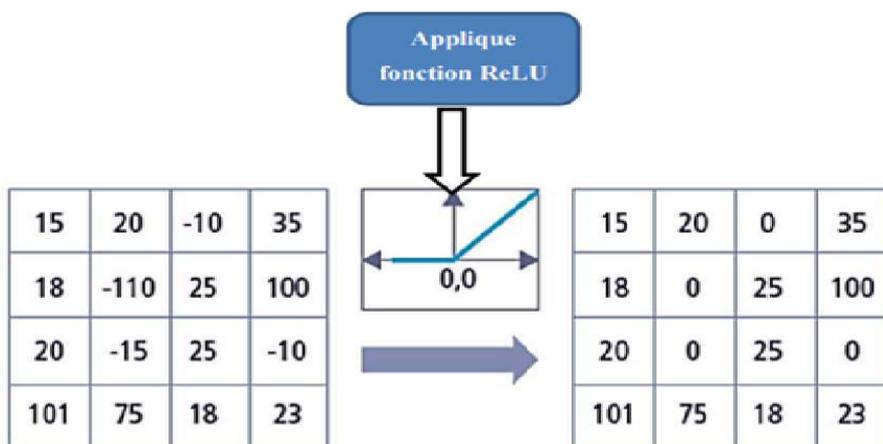


Figure III.9 - Principe de la fonction ReLU.

III.3.3.1.5. Couche entièrement connectée (FC)

La couche entièrement connectée est généralement située à la fin de l'architecture CNN et est utilisée pour classifier l'image en entrée en attribuant des probabilités aux différentes classes. Elle reçoit les caractéristiques extraites par les couches précédentes et les utilise pour effectuer la classification finale de l'image. [25] nous présentons sur la figure III.10 l'architecture de couche entièrement connectée.

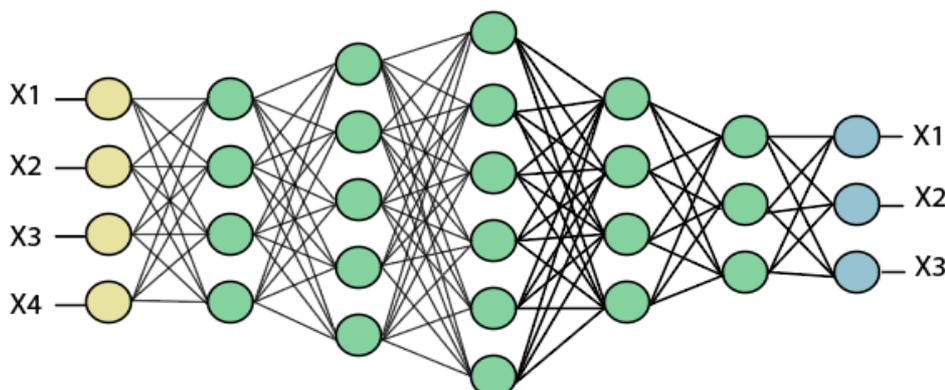


Figure III.10 - Couche entièrement connectée (FC)

III.3.3.1.6. Couche logistique ou softmax (LOSS)

Softmax ou couche logistique est la dernière couche de CNN. Elle réside à la fin de la couche FC. La logistique (sigmoïde) est utilisée pour la classification binaire et softmax est pour la multi-classification.

III.3.3.1.7. Couche de sortie (output Layer)

Dans la couche de sortie, on retrouve l'étiquette qui est codée.

III.3.3. 2. Les différentes architectures du CNN

Les réseaux de neurones convolutifs (CNN) ont évolué avec le temps pour répondre à des défis spécifiques et à des performances améliorées. Figure III.11 montre quelques-unes des architectures les plus remarquables :

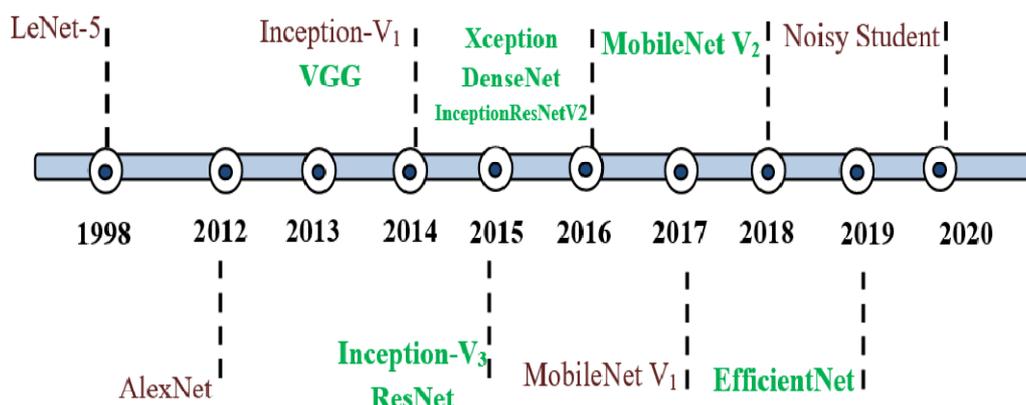


Figure III.11- Histoire évolutive des CNNs montrant les innovations architecturales. [17]

III.3.3.2.1. Le LeNet

Développé par Yann LeCun, LeNet-5 est l'un des premiers CNN à avoir eu du succès. Il a été utilisé pour la reconnaissance de caractères manuscrits, notamment pour le traitement de chèques bancaires. Le modèle était relativement peu profond par rapport aux normes actuelles, avec deux couches de convolution suivies de couches entièrement connectées (voir Figure III.12). [26]

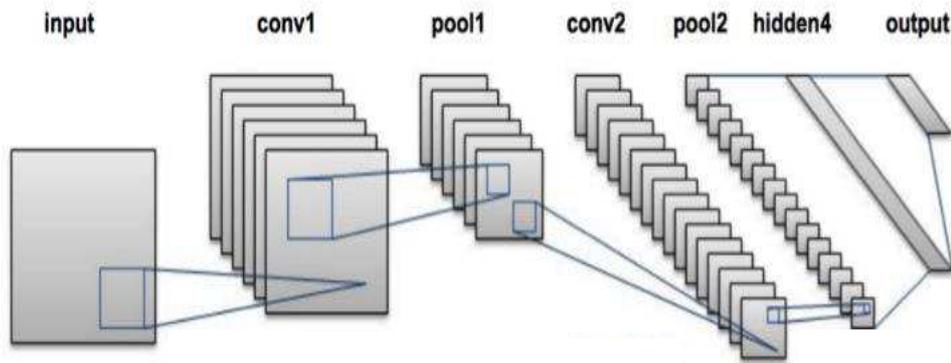


Figure III.12 - L'architecture LeNet. [27]

III.3.3.2.2. Le AlexNet

AlexNet a été une percée majeure dans l'histoire des CNN. Développé par Alex Krizhevsky, Ilya Sutskever et Geoffrey Hinton, il a remporté le défi ImageNet en 2012 avec une grande marge. AlexNet a utilisé cinq couches de convolution, suivies de couches de sous-échantillonnage, et a introduit des techniques telles que l'utilisation de la fonction d'activation ReLU et de la régularisation Dropout. [26] Nous exposons sur la figure III.13 l'architecture d'AlexNet.

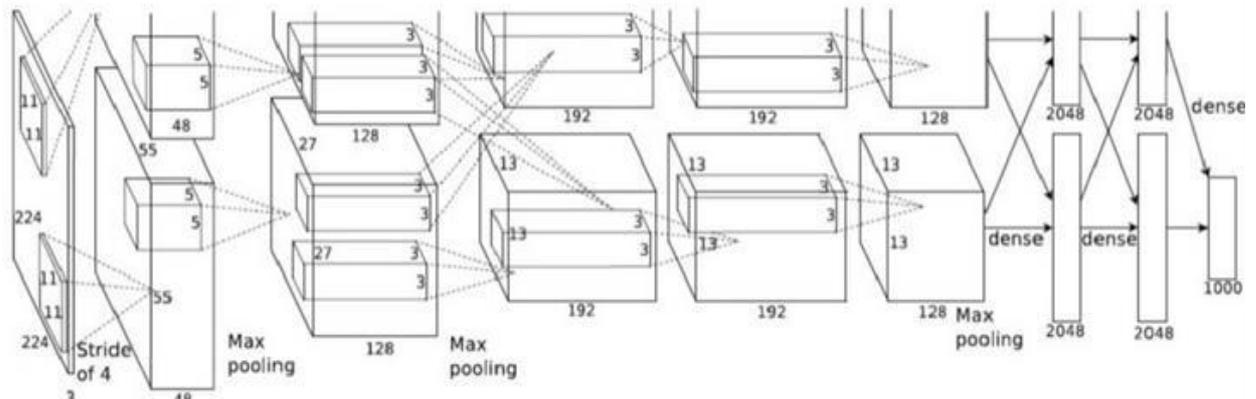


Figure III.13 - L'architecture d'AlexNet.

III.3.3.2.3. Le VGGNet

VGGNet, développé par le Visual Geometry Group à l'université d'Oxford, est réputé pour sa profondeur. Il utilise une architecture très simple mais profonde, avec jusqu'à 19 couches de convolution et de sous-échantillonnage. Cette profondeur accrue a permis au modèle de capturer des caractéristiques complexes, bien que cela ait également conduit à une augmentation significative du nombre de paramètres. [26] Nous exposons sur la figure III.14 l'architecture de VGGNet.

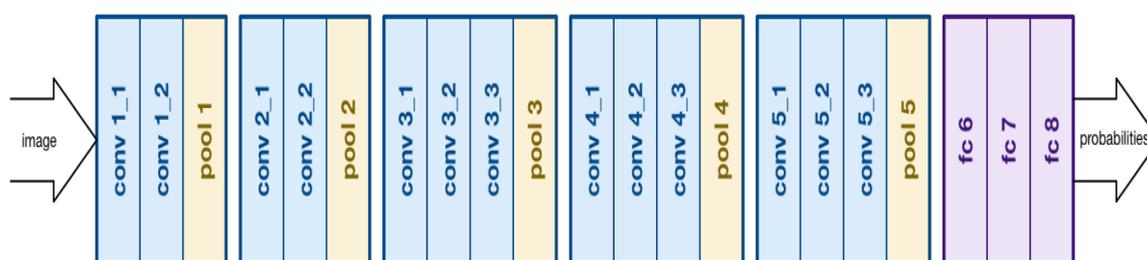


Figure III.14 - L'architecture de VGGNet

III.3.3. 2.4. Le Google-Net (Inception)

Google-Net, développé par Google, est célèbre pour son architecture "Inception". Au lieu d'utiliser des couches de convolution simples, Google-Net utilise des modules d'extraction de caractéristiques parallèles appelés "Inception modules". Ces modules permettent de capturer des caractéristiques à différentes échelles et niveaux d'abstraction, ce qui rend le modèle efficace et précis. [26] Nous montrons sur la figure III.15 l'architecture de Google-Net.

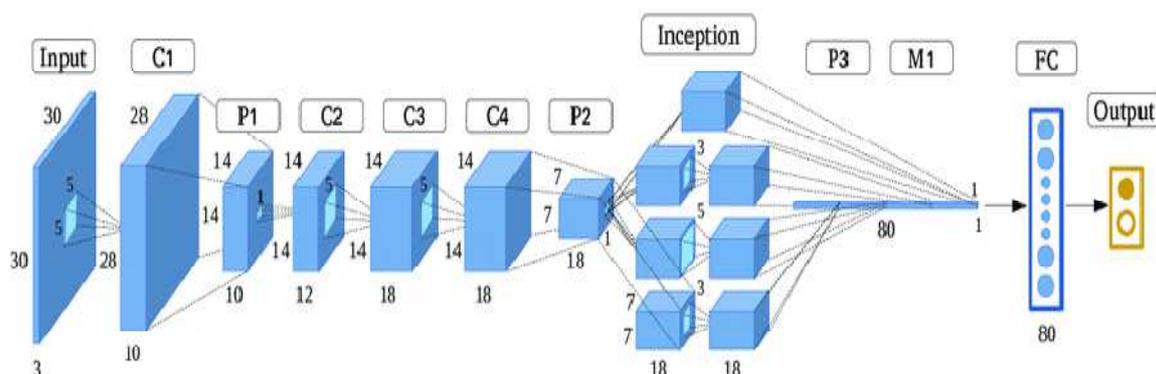


Figure III.15 - L'architecture de Google-Net.

III.3.3.2.5. Le ResNet

Réseau de neurones résiduels (ou ResNet) est une architecture de réseau de neurones profonds utilisée pour la reconnaissance d'images et d'autres tâches de vision par ordinateur. En effet, ce réseau est généré à partir de blocs de construction appelés modules de résidus permettant au réseau de maintenir une performance élevée même dans le cas où le nombre de couches est relativement augmenté.

L'ultime innovation de ResNet réside dans l'utilisation de connexions résiduelles entre les couches du réseau permettant à l'information de sauter au-dessus de certaines couches dans le réseau. En effet, l'avantage de ces connexions résiduelles est de résoudre le problème de la disparition du gradient, pouvant survenir lorsque l'on entraîne un réseau de

neurones relative ment profond. Suite à l'utilisation des connexions résiduelles, le modèle ResNet peut réaliser un apprentissage pertinent avec plus de 100 couches, ce qui a permis d'aboutir à des performances de pointe en ce qui concerne les tâches de vision par ordinateur, citons la classification d'images et la détection d'objets [32]. Nous présentons sur la figure III.16 l'architecture de ResNet.

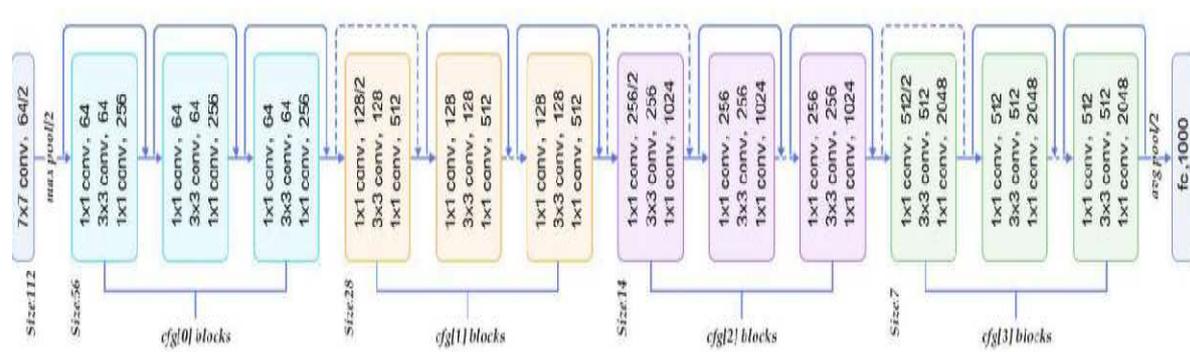


Figure III.16 - L'architecture ResNet

III.3.3.3. L'apprentissage par transfert

L'apprentissage par transfert est une stratégie efficace pour utiliser des modèles de deep learning pré-entraînés sur de grandes quantités de données pour des tâches spécifiques. Plutôt que de construire un modèle à partir de zéro, on peut utiliser un modèle déjà entraîné sur une tâche similaire comme point de départ. Les avantages de l'apprentissage par transfert incluent la réduction du temps et de la puissance de calcul nécessaires pour entraîner un modèle, ainsi que la possibilité de réaliser une meilleure généralisation avec moins de données.

L'idée fondamentale est de prendre un modèle déjà formé, généralement sur une grande base de données comme ImageNet, et de le "transférer" à une tâche spécifique. Les couches initiales du modèle sont souvent conservées et gelées, tandis que les couches supérieures sont adaptées à la nouvelle tâche en modifiant les poids lors de l'entraînement sur un ensemble de données spécifique à cette tâche. [26]

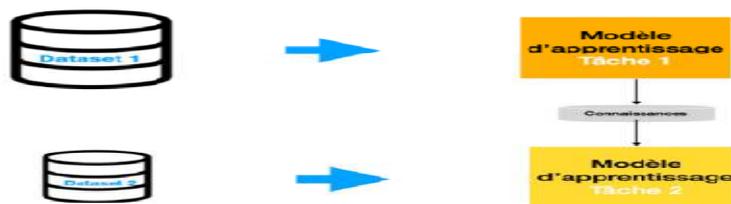


Figure III.17 - L'apprentissage par transfert. [17]

III.3.3.4. Les Avantages et les inconvénients du CNN

Les réseaux de neurones convolutifs (CNN) ont des avantages et des inconvénients différents dans le domaine de l'apprentissage automatique et de l'intelligence artificielle. Voici un récapitulatif des principaux points :

III.3.3.4.1. Avantages du CNN

- Adaptabilité aux grandes quantités de données : Les CNN sont efficaces pour traiter des ensembles de données massifs, comme dans la reconnaissance d'images, grâce à leur capacité à extraire des caractéristiques pertinentes.
- Robustesse face aux distorsions : Les CNN sont résistants aux changements optiques et peuvent traiter des images sous différentes conditions d'éclairage et perspectives.
- Efficacité de stockage : Ils nécessitent moins d'espace de stockage que les réseaux de neurones entièrement connectés en raison de leur structure en couches locales partiellement maillées.
- Temps de formation réduit : Les CNN peuvent être formés de manière efficace en utilisant des processeurs graphiques modernes.
- Technologie de pointe pour le deep learning : Les CNN sont à la pointe du deep learning et de la classification dans la reconnaissance d'images.

III.3.3.4.2. Inconvénients du CNN

- Besoin de grandes quantités de données : La formation des CNN nécessite souvent des ensembles de données volumineux, ce qui peut être un défi pour les données uniques ou difficiles à collecter.
- Coûteux en calcul : Les algorithmes d'apprentissage en profondeur basés sur les CNN exigent une puissance de calcul considérable pour l'entraînement.
- Nature de "boîte noire" : Les CNN peuvent être difficiles à interpréter, car leur fonctionnement interne peut être complexe et difficile à expliquer.

III.4. Conclusion

Au fil de ce chapitre, nous avons accédé diverses notions clés telles que l'intelligence artificielle (IA) et les différents types d'apprentissage automatique, y compris les réseaux de neurones. Ensuite, nous avons exploré en profondeur l'apprentissage profond, ses méthodes distinctes ainsi que quelques domaines d'application. Enfin, une attention particulière a été accordée à la méthode des réseaux de neurones convolutifs (CNN), avec une analyse détaillée de son architecture, de ses différentes couches, ainsi que de ses avantages et inconvénients.

CHAPITRE IV

MISE EN ŒUVRE DE LA CLASSIFICATION

L'analyse et le diagnostic précoce du cancer de la peau sont cruciaux pour améliorer les taux de survie et réduire les coûts de traitement. Cependant, les défis liés à la détection et la classification précoce du cancer de la peau varient considérablement en fonction des ressources disponibles, des infrastructures médicales et du développement technologique des différents pays.

Dans les chapitres précédents, les techniques de traitement et les diverses structures des réseaux de neurones convolutifs (CNN) ont été exposées. Nous exposons et interprétons les résultats obtenus grâce à la modélisation et à la classification des images de la peau. Cette approche a pour objectif d'améliorer la classification des lésions cutanées malignes et bénignes, tout en fournissant un outil efficace aux professionnels de santé.

IV.1. Introduction

Le cancer de la peau est une maladie qui implique la croissance de cellules anormales dans les tissus de la peau. En règle générale, à mesure que les cellules de la peau vieillissent et meurent, de nouvelles cellules se forment pour les remplacer. En cas de dysfonctionnement de ce processus, comme après une exposition aux rayons ultraviolets (UV), les cellules se développent plus rapidement. Il est possible que ces cellules ne soient pas cancéreuses (bénignes), ne se propagent pas ou ne causent pas de dommages.

L'intelligence artificielle (IA) et, en particulier, les réseaux de neurones convolutifs (CNN) ont émergé comme des outils puissants pour l'analyse et la classification des images médicales. Ces technologies permettent de détecter les lésions cutanées à partir d'images de haute résolution, améliorant ainsi la capacité des professionnels de santé à diagnostiquer le cancer de la peau de manière plus efficace et précise.

Dans ce contexte, notre étude se concentre sur l'utilisation des architectures CNN, notamment ResNet18 et VGG16, pour la classification du cancer de la peau. Ces modèles ont été sélectionnés pour leur performance avérée dans la classification d'images complexes et leur capacité à extraire des caractéristiques discriminantes pertinentes pour différencier les lésions bénignes des lésions malignes.

L'objectif de ce travail est de développer et d'évaluer un système de la classification automatique du cancer de la peau, capable d'analyser des images dermatologiques et de fournir des diagnostics fiables. Cela inclut la préparation et le prétraitement des données, la formation des modèles CNN, et l'évaluation de leurs performances à l'aide de métriques telles que la précision.

Dans les sections suivantes, nous décrivons en détail les méthodes et les algorithmes utilisés, les bases de données d'images de peau exploitées, ainsi que les résultats obtenus. Cette étude vise à démontrer le potentiel des techniques de deep learning pour améliorer les outils de diagnostic médical et à offrir des perspectives pour leur intégration dans la pratique clinique quotidienne.

IV.2. Environnement de développement

La mise en place d'une application implique de gérer des informations, de les sauvegarder et de les traiter de différentes manières. Avant de résoudre un problème quelconque, il faut bien le connaître et l'analyser avec les moindres détails. Après cette

analyse, la position du problème est suffisamment formulée de telle manière que nous pouvons implémenter la solution en utilisant un langage choisi.

IV.2.1. Outil de développement : MATLAB R2022b

IV.2.1.1. Définition

MATLAB est un logiciel de calcul et de visualisation, dont les entités de base sont des matrices : MATLAB est une abréviation de Matrix Laboratory. C'est un langage interprété, il propose des facilités de programmation et de visualisation, ainsi qu'un grand nombre de fonctions réalisant diverses méthodes numériques.

IV.2.2. Base de données

Au cours des dernières années, les ensembles de données de référence publics bien établis utilisés dans la littérature ont été fournis par les archives de l'International Skin Imaging Collaboration (ISIC), qui contient des images dermoscopiques (RGB) recueillies auprès de différents leaders internationaux de centres cliniques, obtenus à partir de divers dispositifs utilisés au sein de chaque centre. Nous avons utilisé l'ensemble de données de référence publiques ISIC 2019 bien établi dans l'évaluation du modèle proposé.

IV.3. Les architectures du VGG16 & ResNet18 : Modèles (CNN)

Les réseaux convolutifs également connus sous le nom Convolutional Neural Network est une classe de réseaux neuronaux d'apprentissage en profondeur. Les CNN représentent un grand avancement dans la reconnaissance d'images. Ils sont le plus souvent utilisés pour analyser les images visuelles et travaillent fréquemment dans les coulisses de la classification des images.

Le choix entre ResNet18 et VGG16 dépend souvent des contraintes spécifiques de la tâche et des ressources disponibles. Ces deux architectures ont des structures différentes mais visent à résoudre le même problème de classification d'images.

IV.3.1. Le modèle ResNet18 (Résiduel Network)

ResNet18 est un réseau de neurones convolutifs (CNN) profond introduit par Microsoft en 2015. ResNet18 est une architecture à 72 couches avec 18 couches profondes. L'architecture de ce réseau visait à permettre à de grandes quantités de couches convolutives de fonctionner efficacement. Cependant, l'ajout de plusieurs couches profondes à un réseau

entraîne souvent une dégradation de la sortie. Le modèle est implémenté dans le cadre MATLAB, comme illustré dans la figure IV.1.

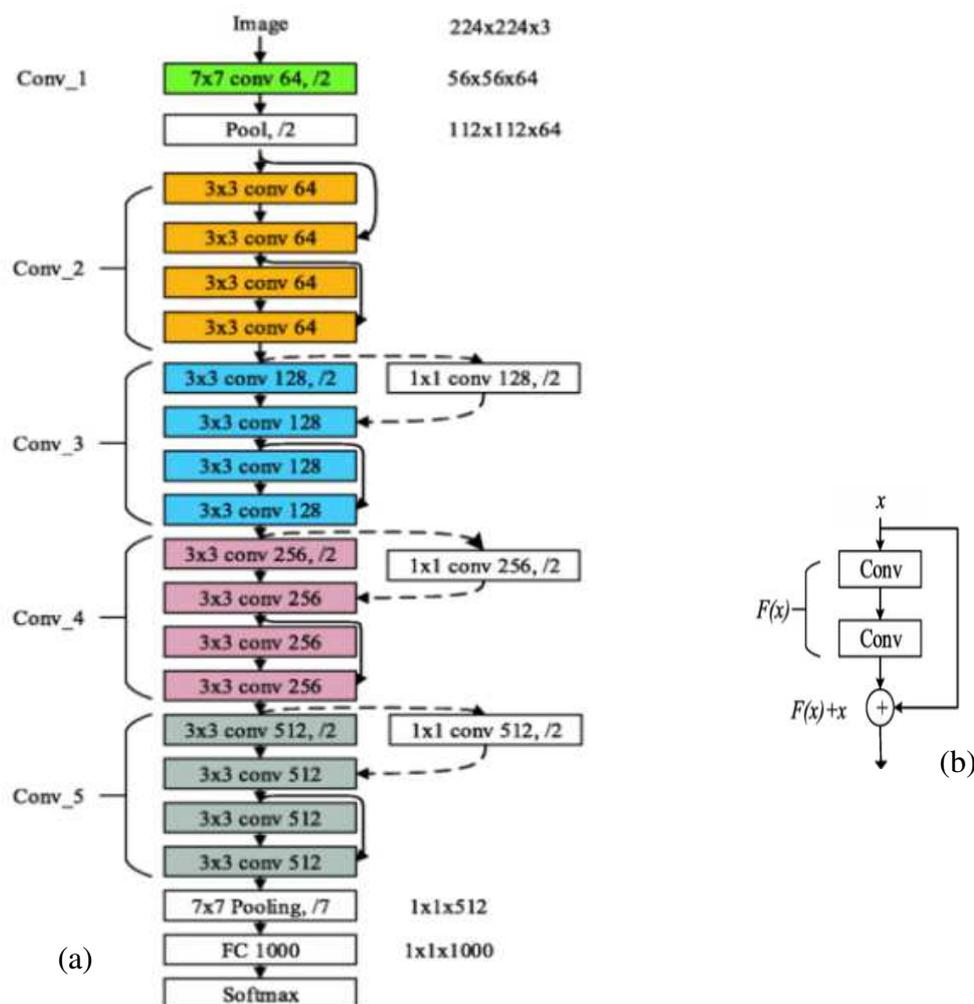


Figure IV.1 - L'architecture du ResNet18.

(a) structure originale de ResNet18, (b) structure du bloc résiduel, ajout d'une connexion de saut de la couche avant la première convolution à l'opération de sommation. [34]

- ResNet18 accepte des entrées de taille (224, 224, 3), où 224 représente la largeur et la hauteur, et 3 représente les canaux RGB. La sortie du modèle est une couche entièrement connectée (FC) qui sert d'entrée à une couche séquentielle.
- ResNet18 est composé de 18 couches, avec une première couche utilisant un noyau de taille 7x7. Il contient quatre ensembles de couches de convolution identiques, chacun constitué de deux blocs résiduels.
- Chaque bloc résiduel inclut deux couches pondérées, avec une connexion skip qui relie la sortie de la deuxième couche pondérée à une activation ReLU.

- Si la sortie est identique à l'entrée de la couche ConvNet, une connexion d'identité est utilisée. Sinon, une convolution est appliquée sur la connexion skip.
- L'entrée passe ensuite par une couche linéaire de dimensions (512, 512), dont la sortie est transmise à une fonction d'activation ReLU. Ensuite, une couche dropout est appliquée, suivie d'une couche linéaire de dimensions (512, 2).
- Enfin, les résultats passent par un Softmax pour obtenir le logarithme des probabilités.

Le modèle ResNet18 que nous allons utiliser est de modèle préentraîné sur des millions d'images de la base ImageNet. Nous allons également créer une couche de classification spécifique à nos données.

IV.3.2. Le modèle VGG16

VGG16 est un autre CNN très populaire développé par Visual Graphics Group (VGG) de l'Université d'Oxford en 2014. Il se compose de 16 couches de convolution et de pooling, suivi de trois couches entièrement connectées pour la classification. VGG16 est caractérisé par l'utilisation de petites convolutions (3x3) avec un pas de 1 et une même taille de padding, ce qui donne une architecture simple et uniforme. Le modèle est implémenté dans le cadre MATLAB, comme illustré dans la figure IV.2.

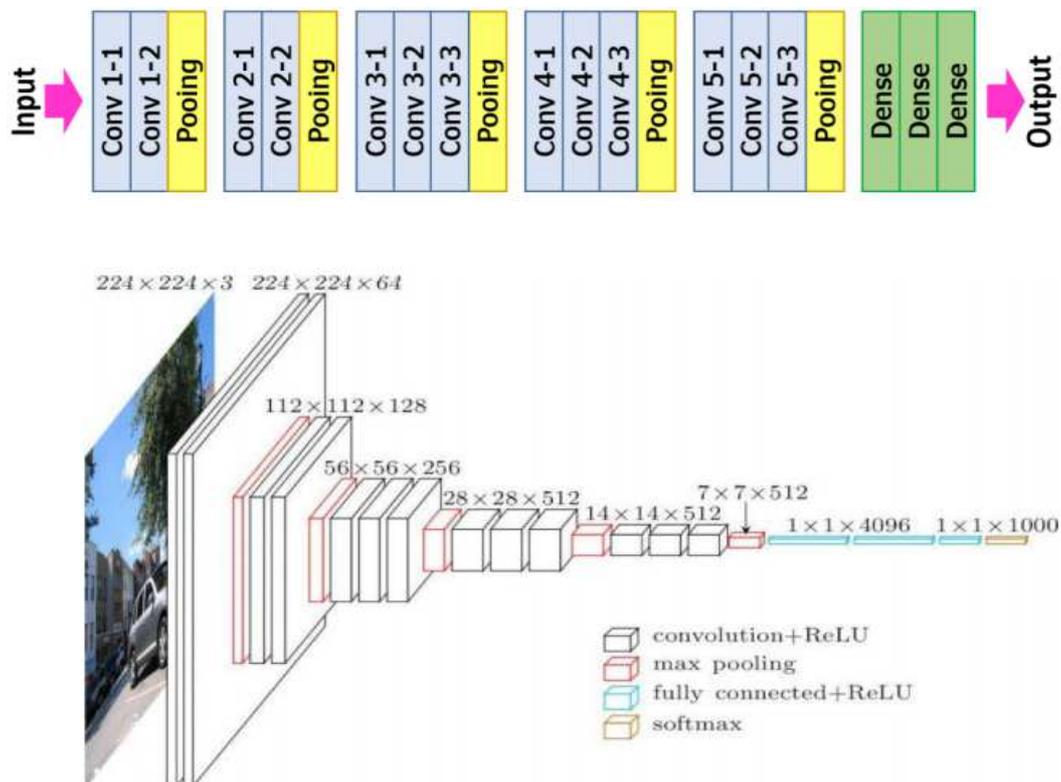


Figure IV.2 - L'architecture du VGG16. [34]

- On fixe la taille de l'entrée de la couche Cov1 à 224×224 images RGB.
- L'image est passée à travers la pile de couches convolutionnaires, On a utilisé des filtres avec un champ réceptif très petit : 3×3 (ce qui est le plus petit pour capturer la notion de gauche/droite, haut/bas, centre).
- Une des configurations utilise également les filtres de convolution 1×1 , qui peuvent être vus comme la transformation linéaire des canaux d'entrée.
- La stride de convolution est fixée au 1 pixel. Le remplissage spatial de la convolution. La couche d'entrée est telle que la résolution spatiale est préservée après la convolution, c.-à-d. le remplissage est de 1 pixel pour 3×3 couches de convolution.
- Le regroupement spatial est effectué par les cinq couches de regroupement maximales, qui suivent certaines des couches de convolution. Le regroupement maximal est effectué sur la fenêtre de 2×2 pixels, avec stride 2.
- Trois couches fully connected (FC) suivent la pile de couches convolutionnaires (qui a la profondeur différente dans différentes architectures) : les deux premières ont 4096 canaux chacune, la troisième effectue 1000 voies de classification (contient donc 1000 canaux).
- La couche finale est la couche Softmax. Les configurations des couches entièrement connectées sont les mêmes dans tous les réseaux. Toutes les couches cachées sont équipées de la non-linéarité de rectification (ReLU).

Le modèle VGG 16 que nous allons utiliser est de modèle préentraîné sur des millions d'images de la base ImageNet. Nous allons également créer une couche de classification spécifique à nos données.

IV.4. Conception du système

IV.4.1. Objectif

L'objectif de notre travail est de classifier des images médicales pour la classification des pathologies. Ainsi de démontrer le potentiel des techniques de deep learning pour améliorer les outils de diagnostic du cancer de la peau, fournissant ainsi un support efficace aux professionnels de santé dans leur pratique clinique.

IV.4.2. Schéma général de conception

La conception du système de soutien diagnostique proposé nécessite des étapes décrites à la figure IV.3.

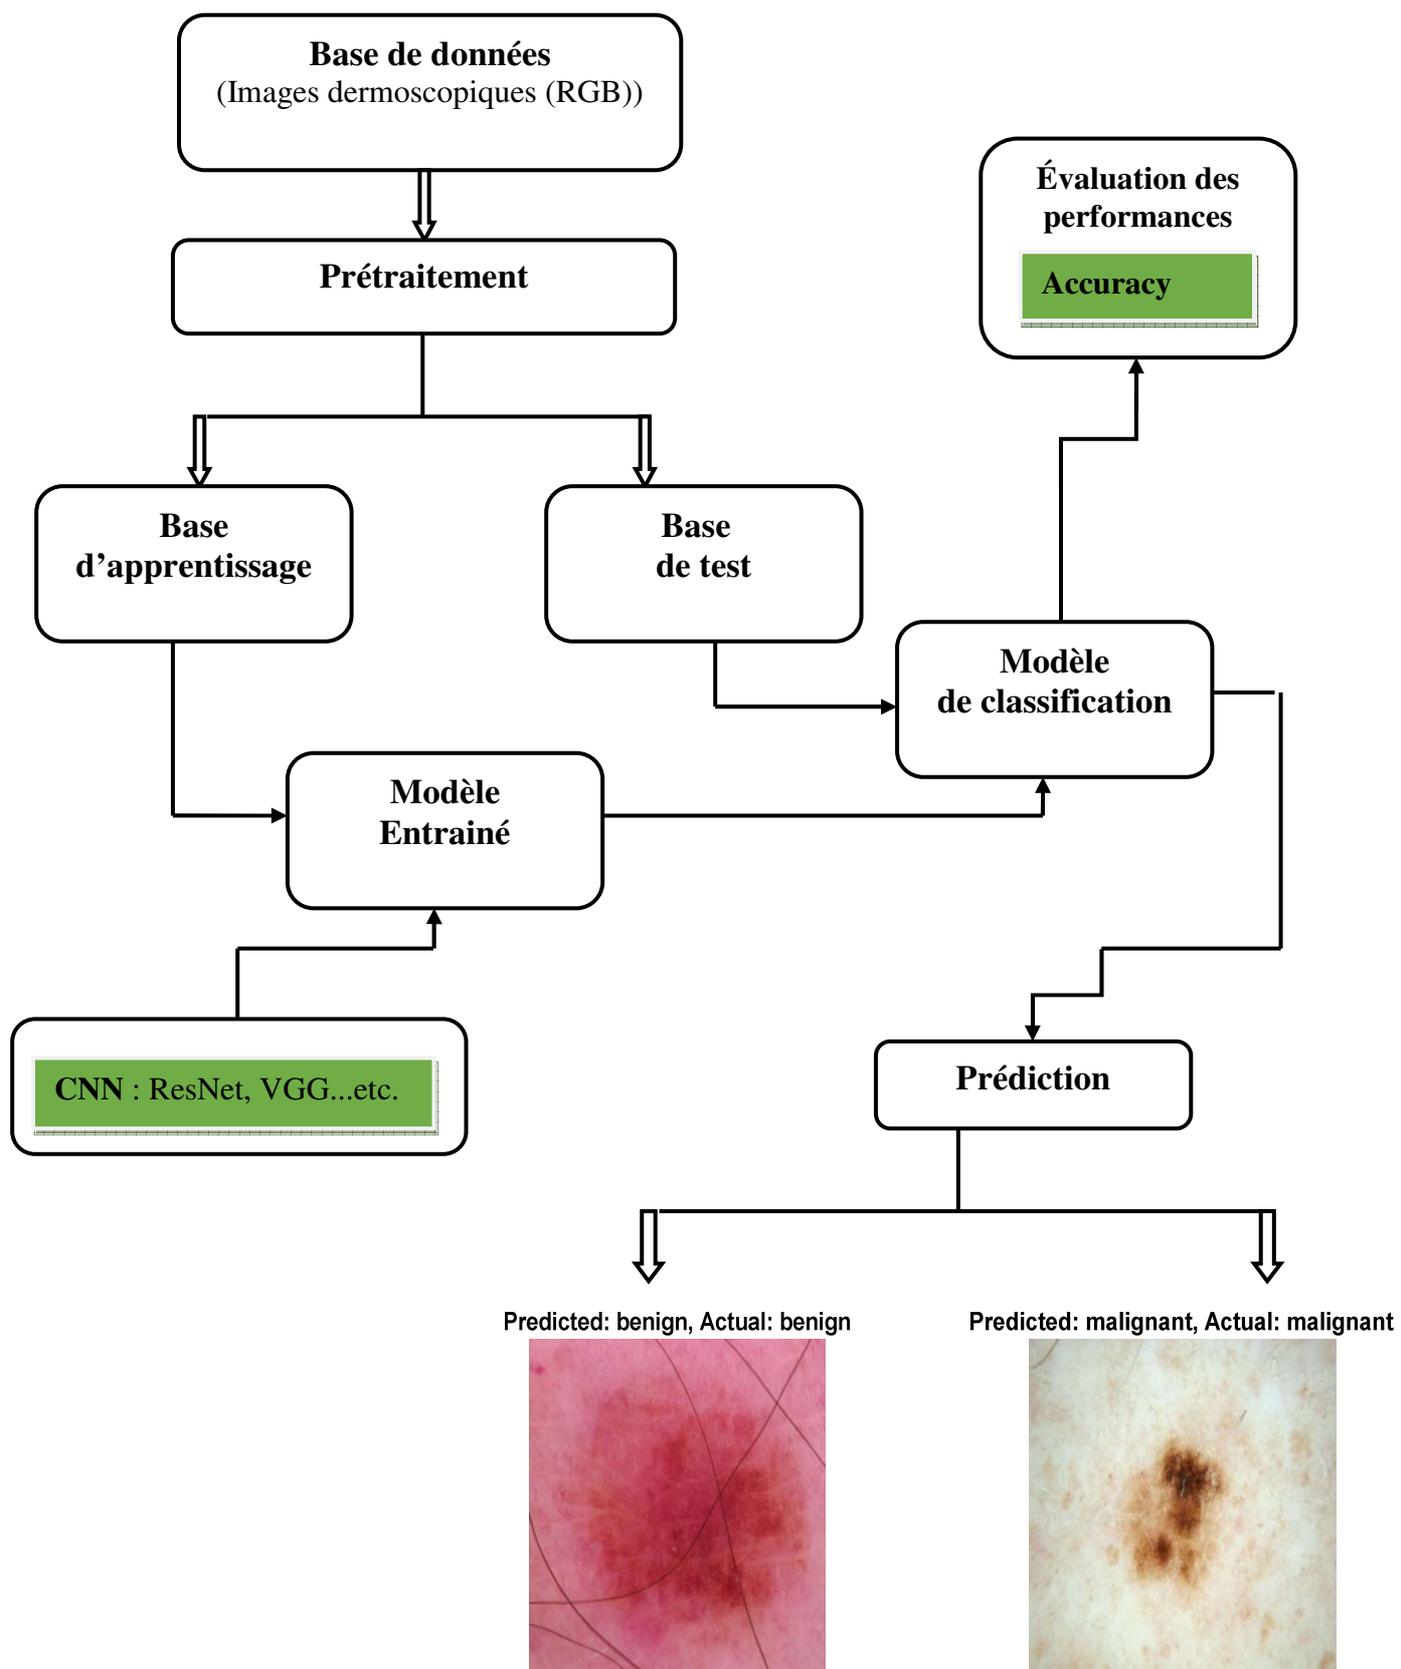


Figure IV.3 - Schéma général de conception

IV.5. Évaluation des performances de classification

Dans le cas général, nous expérimentons et évaluons nos algorithmes de la classification en utilisant les images réelles. Dans cette section, nous allons détailler les critères d'évaluation utilisés pour mesurer la performance des modèles de la classification du cancer de la peau, ainsi que les optimisateurs employés pour l'entraînement des modèles, notamment Adam, RMSprop et SGDM. Plusieurs métriques sont utilisées pour évaluer les performances d'un classifieur. Parmi les quelles, nous citons :

IV.5.1. Evaluation de la robustesse

La robustesse a été définie comme la capacité de l'algorithme automatique proposé à donner des résultats de classification adéquats dans les images de la peau au niveau de la prise de décision bénigne ou maligne.

IV.5.2. Evaluation de la précision (Accuracy)

La précision de la classification est une métrique clé. Il est important d'obtenir une estimation quantitative de la précision de la classification. Pour ce faire, une stratégie courante consiste à diviser vos échantillons d'entraînement en deux fractions aléatoires - l'une utilisée pour l'entraînement (training) du modèle et l'autre pour la validation des prédictions. Une fois le modèle entraîné, il peut être utilisé pour classer les échantillons de validation, et les prédictions peuvent être comparées aux valeurs réelles pour calculer la précision.

$$\text{Précision (Accuracy)} = \left(\frac{TP+TN}{TP+TN+FP+FN} \right) \times 100$$

Où

- VP (Vrais Positifs) : Nombre de cas de cancer de la peau malins correctement identifiés comme malins par le modèle.
- VN (Vrais Négatifs) : Nombre de cas de peau bénins correctement identifiés comme bénins par le modèle.
- FN (Faux Négatifs): Nombre de cas de cancer de la peau malins incorrectement classés comme bénins.
- FP (Faux Positifs): Nombre de cas de peau bénigne incorrectement classés comme malins.

IV.6. Résultats expérimentaux

Nous avons analysé les méthodes de classification basées sur l'apprentissage profond, que nous avons étudiée aux chapitres précédents, sur une série d'images dermoscopiques (RGB) réelles couleurs de taille $224 \times 224 \times 3$.

IV.6.1. Présentation des résultats

Les exemples traités sont des images couleur de même taille. Cette série d'expérimentations concerne des images dermoscopiques réelles, pour lesquelles il existe deux cas de cancer de la peau maligne et bénigne. Cependant, il est possible d'obtenir un avis d'expert sur le type de cancer. L'objectif de ces exemples étant d'obtenir :

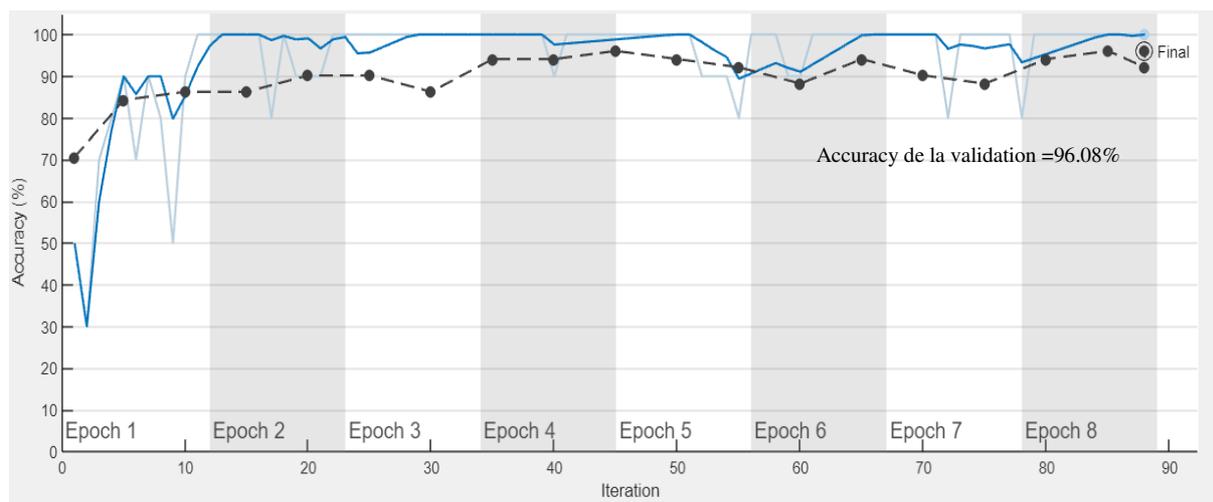
- Procéder une analyse détaillée des résultats expérimentaux obtenus lors de la classification du cancer de la peau en utilisant les deux modèles ResNet18 et VGG16 tout en appliquant différents types de prétraitement sur les images. Ces prétraitements comprennent : l'adaptation d'histogramme sur les images en niveau de gris, l'égalisation d'histogramme adaptative, et la méthode des ondelettes.
- Détailler les critères d'évaluation utilisés pour mesurer la performance des modèles choisis de classification du cancer de la peau, ainsi que les optimisateurs employés pour l'entraînement des modèles, notamment Adam, RMSprop, et SGDM. Les résultats illustrent que la fonction Adam donne des résultats exceptionnels.
- Afin d'évaluer les performances du classifieur, nous avons considéré deux cas de figure :
 - ❖ **1^{er} Cas** : la base d'apprentissage est formée de 80 % d'images prises aléatoirement de la base de données et la base de test est constituée de 20 % des images restantes.
 - ❖ **2^{ème} Cas** : la base d'apprentissage est formée de 70 % d'images prises aléatoirement de la base de données et la base de test est constituée de 30 % des images restantes.

IV.6.2. Analyse et discussion

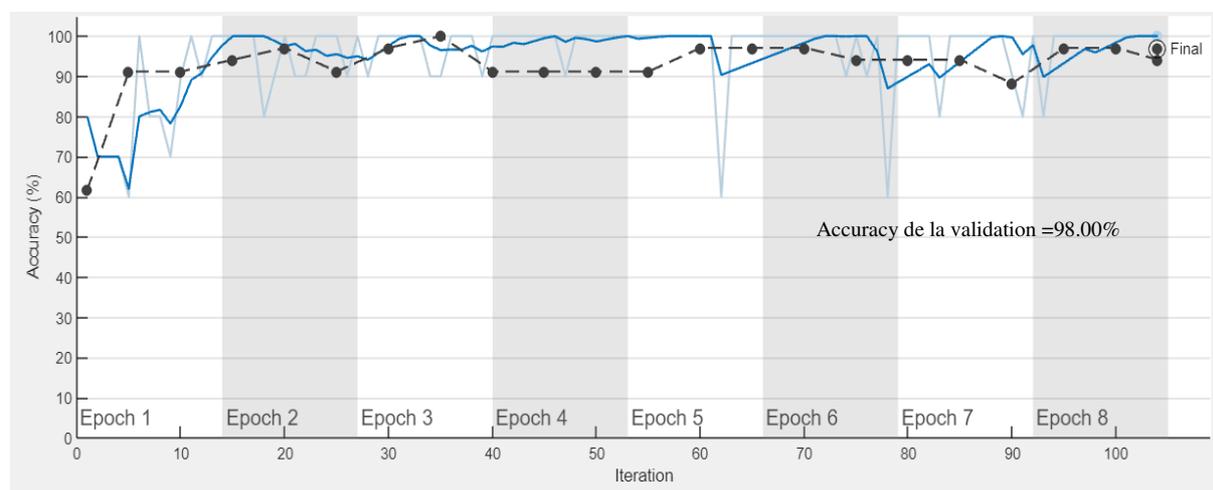
Les résultats expérimentaux obtenus à l'aide des modèles ResNet18 et VGG16 sont présentés de manière comparative. Les performances de chaque modèle sont détaillées en termes de précision.

- Dans le but d'évaluer les performances du classifieur, nous avons analysé deux cas. Les résultats de la précision (accuracy) ci-dessous indiquent que le système proposé dans le 2^{ème}

cas n'a pas bien reconnu tous les exemples présentés, comme le montre bien la valeur de la précision obtenue (96.08% pour le ResNet18 et 88.24% pour le VGG16). Il est évident que la précision a diminué, et cela est dû au fait que le nombre d'images constituant la base d'apprentissage est moins important dans le deuxième cas (70%) ; le classifieur n'a pas assez d'exemples pour bien apprendre les classes. Les modèles de la précision (accuracy) obtenues sont transposés sur les figures : figure IV.4 et figure IV.5.



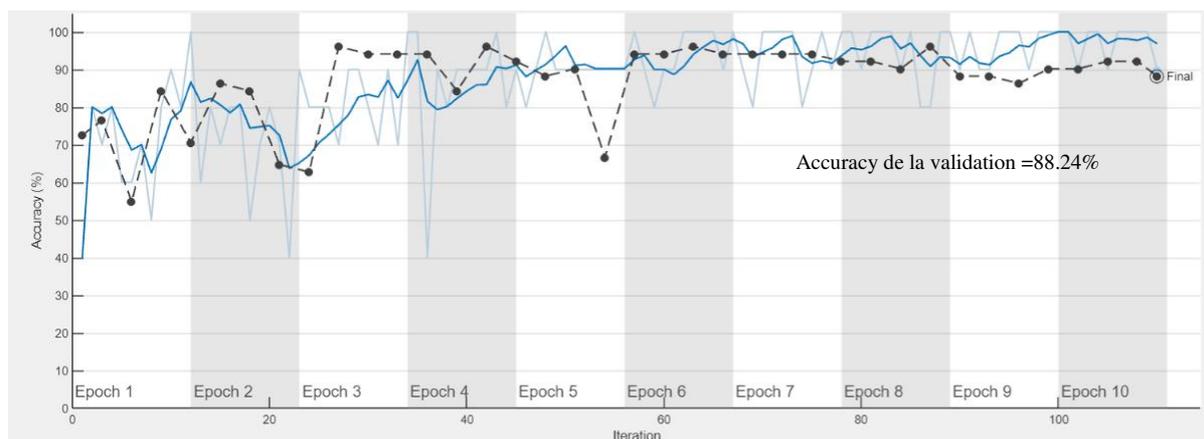
(a)



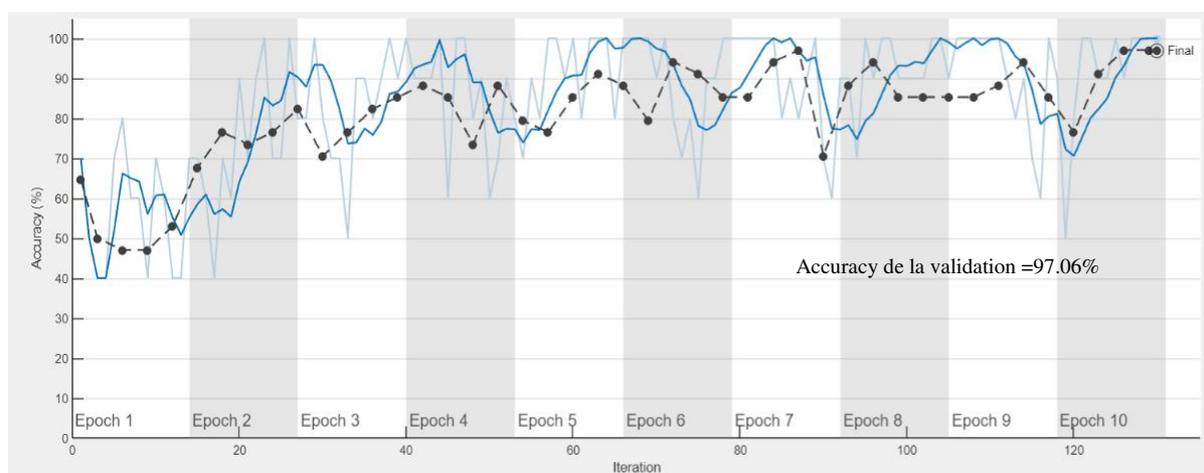
(b)



Figure IV.4 : Le modèle de la précision (accuracy) pour l'apprentissage et le teste avec ResNet18. (a) Le modèle accuracy pour 2^{ème} cas; (b) le modèle accuracy pour 1^{ème} cas (L'apprentissage est formé de 80 % d'images).



(a)



(b)

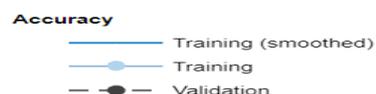


Figure IV.5 : Le modèle de la précision (accuracy) pour l'apprentissage et le teste avec VGG16.

(a) Le modèle accuracy pour 2^{ème} cas et (b) le modèle accuracy pour 1^{ème} cas.

D'après les deux Figures ci-dessus (figure IV.4 et figure IV.5), la base de données et les résultats ont montré qu'il faut au moins prendre 80 % de la base de données comme étant la base d'apprentissage afin d'avoir un taux de reconnaissance très élevé (98% pour le ResNet18 et 97.06% pour le VGG16). Dans le cadre des traitements ultérieurs. La base d'apprentissage, qui contient 80 % d'images aléatoires extraites de la base de données, sera utilisée.

- Le contraste a été amélioré en appliquant divers types de prétraitement sur les images. Les prétraitements de ces images obtenues sont reportés sur les figures : figure IV.6. (b), figure IV.6. (c) et figure IV.6. (d).

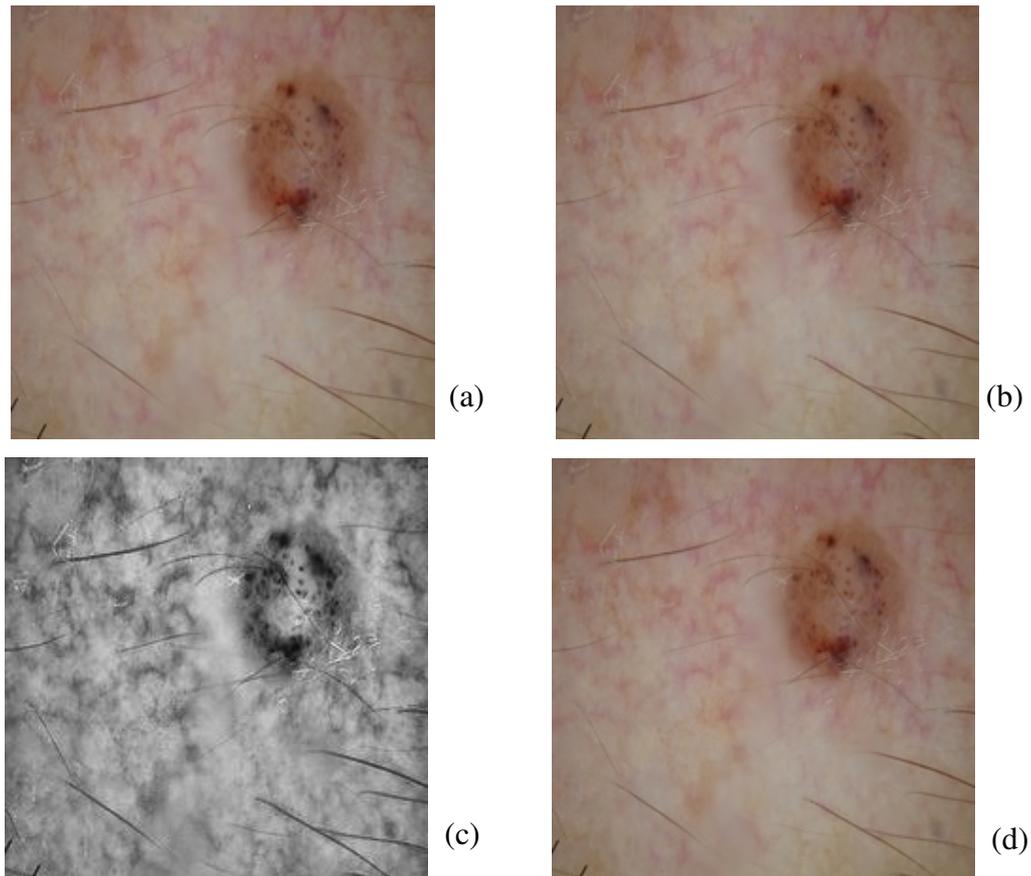
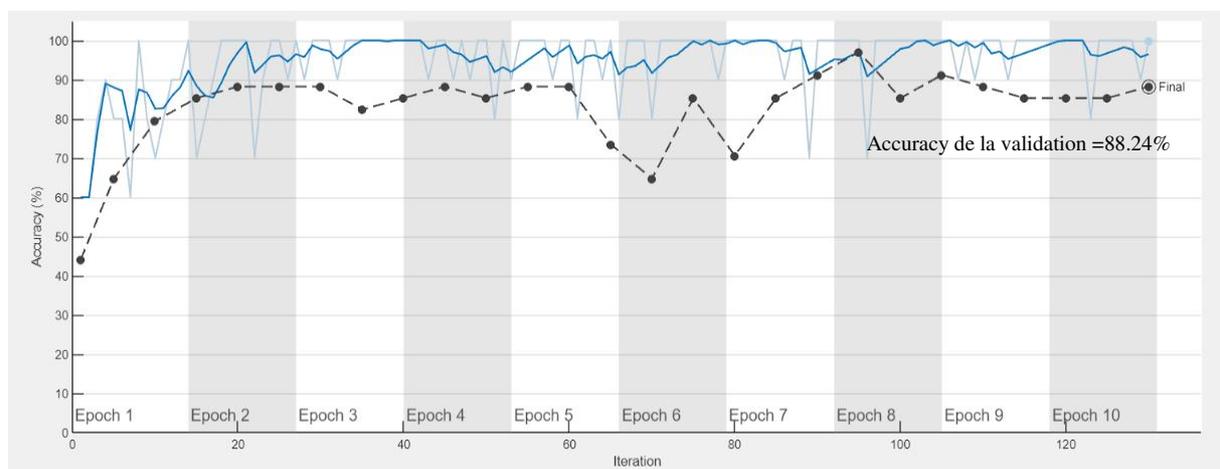


Figure IV.6 - Résultats après le prétraitement.

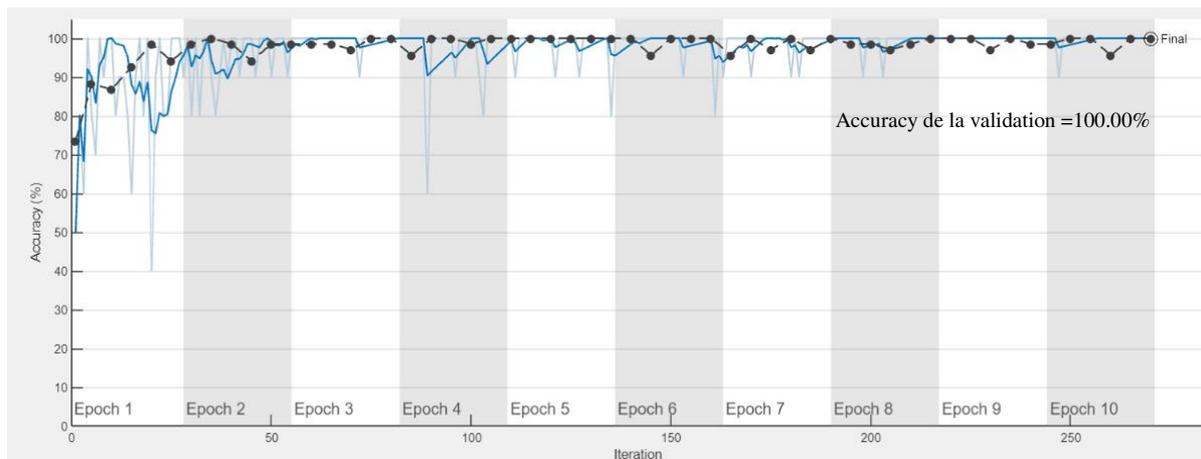
(a) Image originale, (b) avec l'égalisation d'histogramme adaptative, (c) avec l'adaptation d'histogramme sur les images en niveau de gris, (d) avec l'ondelette.

- Les performances de chaque méthode de prétraitement sont évaluées sur ResNet18 (ou VGG16), en mettant en avant leurs avantages et leurs inconvénients. Les modèles de la précision (accuracy) obtenues sont transposés sur les figures : figure IV.7 et figure IV.8.

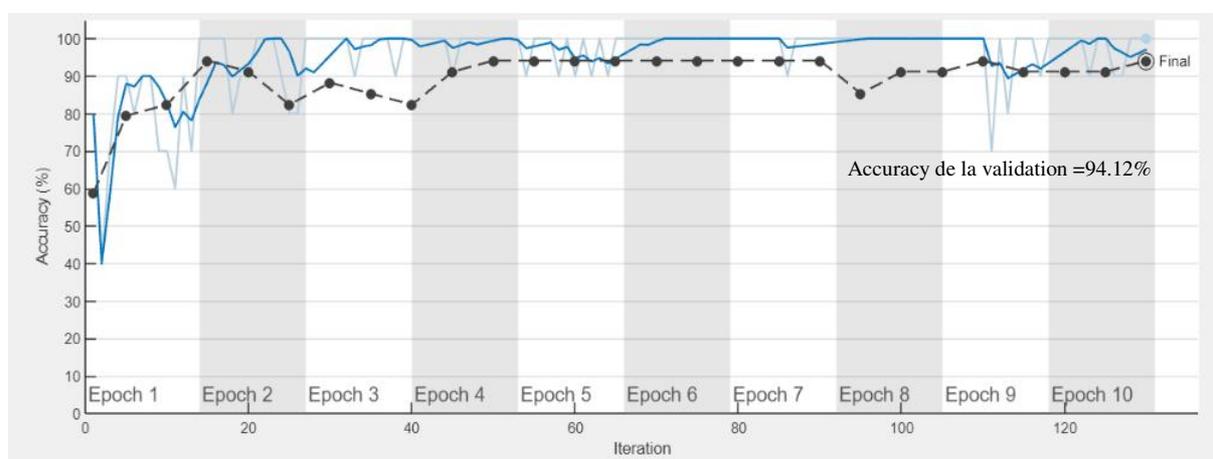
Le modèle ResNet18 avec les différentes méthodes de prétraitement



(a)



(b)



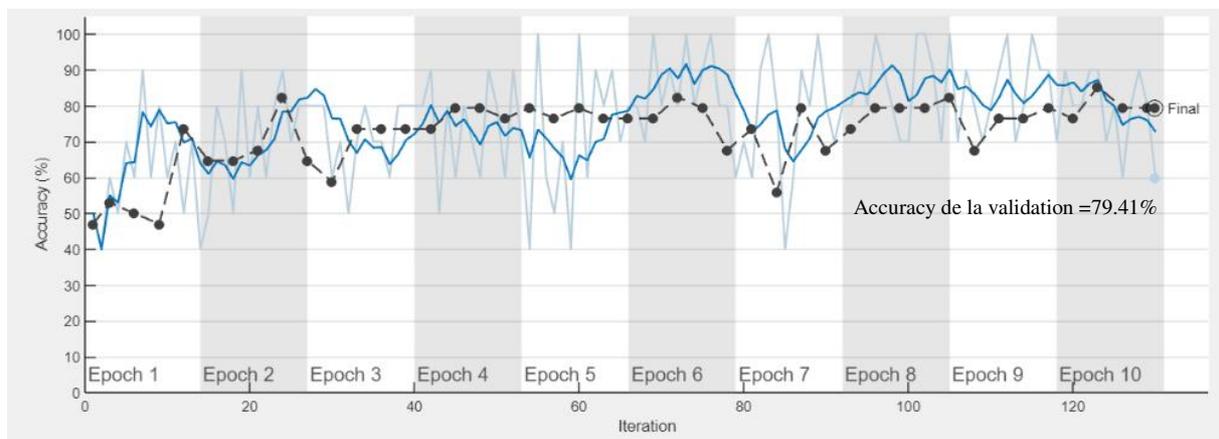
(c)

Accuracy
 — Training (smoothed)
 — Training
 - - Validation

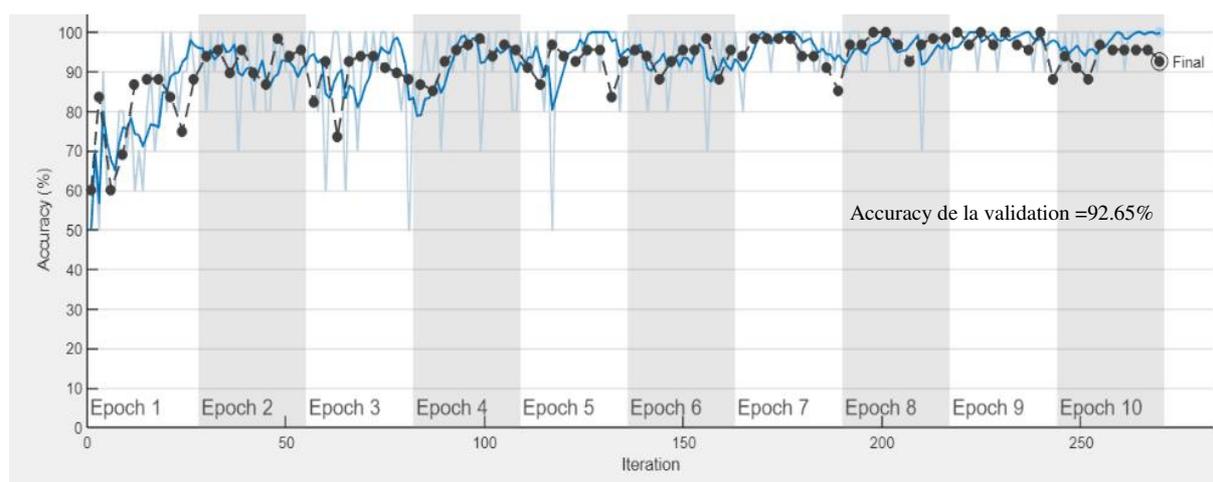
Figure IV.7 - Le modèle de la précision (accuracy) de la classification avec ResNet18.

(a) Le modèle par la méthode d'égalisation d'histogramme, (b) le modèle par la méthode d'égalisation d'histogramme adaptative et (c) par le modèle par la méthode des ondelettes.

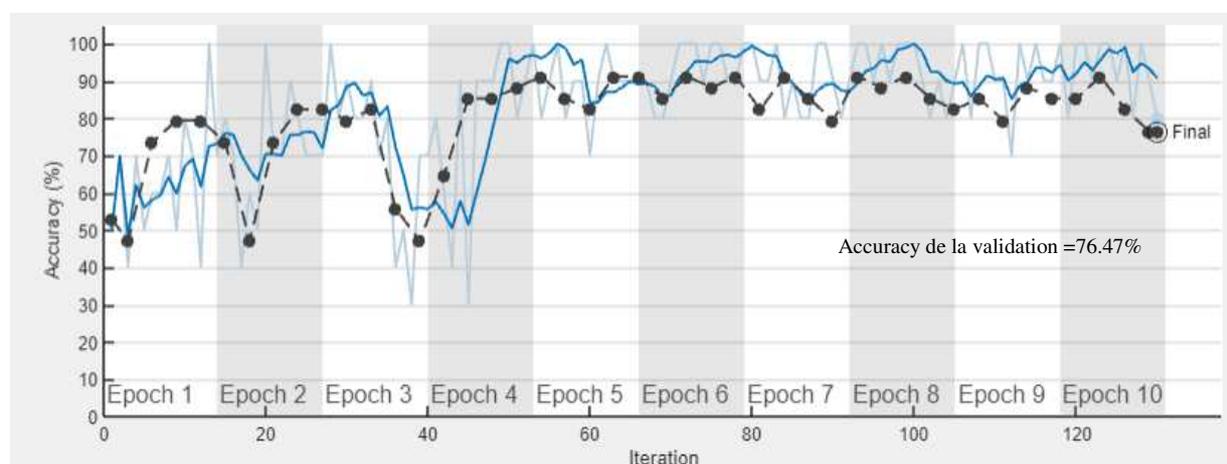
Le modèle VGG16 avec les différentes méthodes de prétraitement



(a)



(b)



(c)

Accuracy

- Training (smoothed)
- Training
- - ● - Validation

Figure IV.8 : Le modèle de la précision (accuracy) de la classification avec VGG16.

(a) Le modèle par la méthode d'égalisation d'histogramme, (b) le modèle par la méthode d'égalisation d'histogramme adaptative et (c) par le modèle par la méthode des ondelettes.

- En se basant sur les résultats des modèles de la précision présentés sur les figures (IV.7 et IV.8) ci-dessus, l'égalisation d'un histogramme adaptative est la méthode la plus performante pour le prétraitement. En combinant cette technique avec le modèle ResNet18 (ou VGG16) et l'optimiseur Adam. Le modèle ResNet18 a obtenu les meilleures performances en matière de précision grâce à cette combinaison, avec une précision de 100%. La précision de cette classification est illustrée dans la figures (IV.9 et IV.10). Nous pouvons voir ici que les scores de précision à la dernière époque sont respectivement de 100.00 % pour les données d'entraînement et 100.00 % pour le test pour le ResNet18. Et la sortie ressemble aux deux Figures ci-dessous :

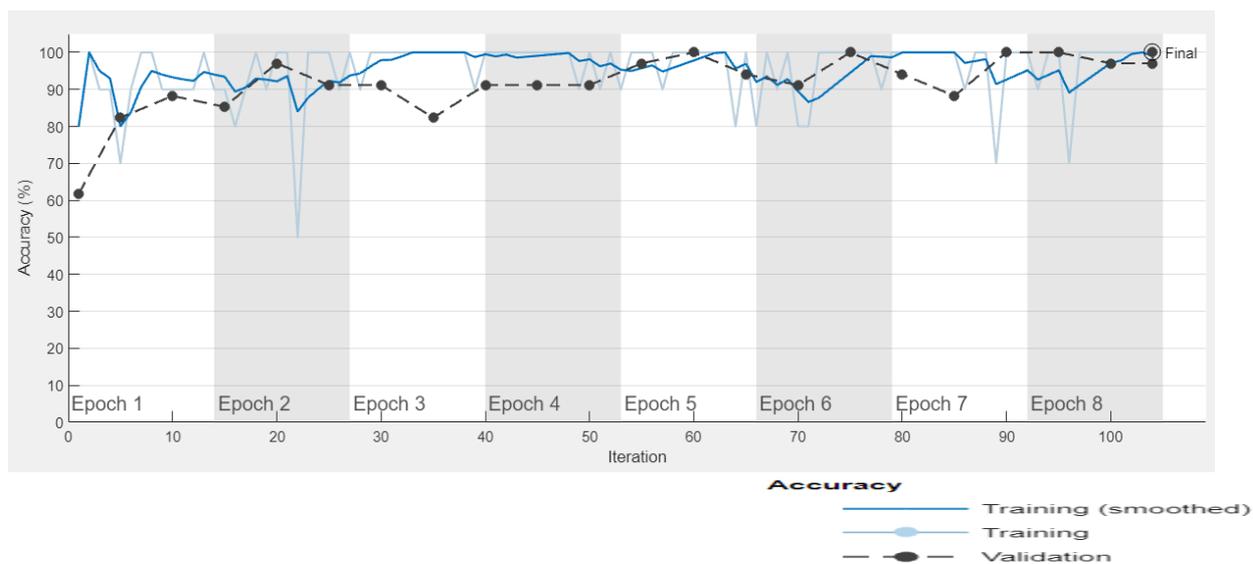


Figure IV.9 - Le modèle de la précision (accuracy) pour l'apprentissage et le teste.

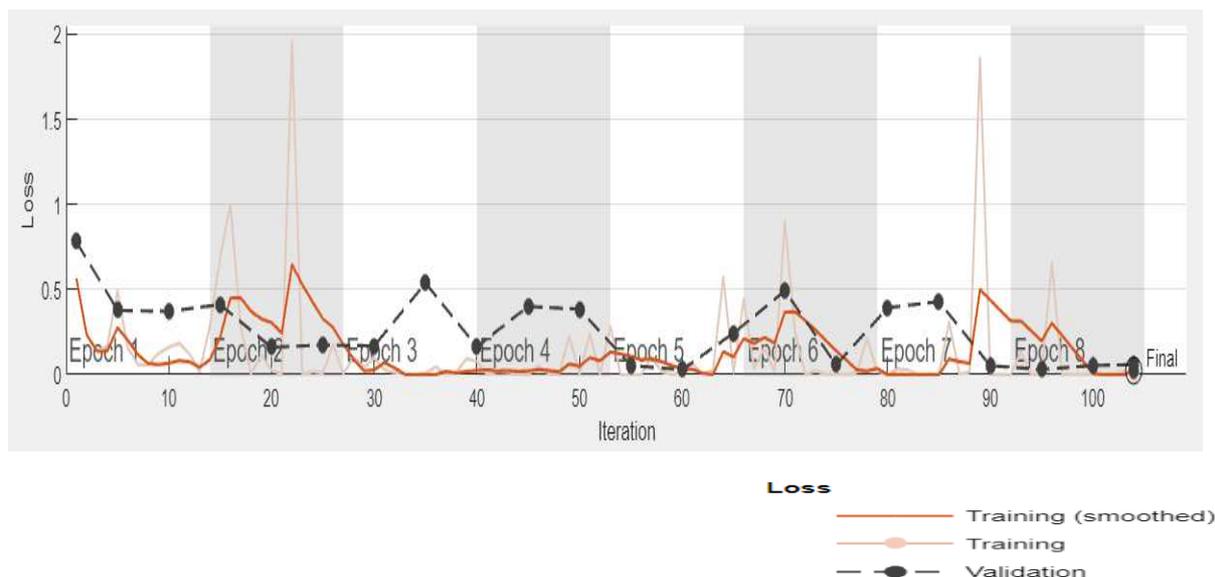


Figure IV.10 - Le modèle de perte (loss) pour l'apprentissage et le teste.

D'après les deux graphiques ci-dessus, nous pouvons voir que notre modèle fonctionne plutôt parfaitement car il atteint la précision finale de 100% pour les données de train et de test respectivement. En outre, les deux valeurs de perte (loss) sont un peu stables mais ils diminuent au fil du temps, également à mesure que le nombre d'époques augmente.

IV.7. Conclusion

Dans ce chapitre, nous avons mis au point un système automatisé de la classification du cancer de la peau. L'algorithme développé est basé sur l'utilisation des architectures de réseaux de neurones profonds tels que ResNet18 et VGG16. Nos résultats montrent que l'égalisation d'histogrammes adaptatifs, combinée avec ResNet18 et l'optimiseur Adam, a produit les meilleures performances en termes de précision avec une précision de 100 %. Cette méthode s'est révélée particulièrement efficace pour distinguer les cas de cancer de la peau malins des cas bénins.

V.1. Récapitulatif

Dans ce mémoire, nous avons exploré divers axes liés au traitement des images médicales et à l'application de l'intelligence artificielle (IA) pour la classification du cancer de la peau. Les principaux axes de notre travail peuvent être récapitulés comme suit :

- Étude des images.
- Pour faire cette étude, nous avons traité des images médicales.
 - i) On a examiné les caractéristiques et les spécificités des images utilisées en imagerie médicale, en soulignant l'importance de la qualité et de la précision dans le diagnostic médical.
 - ii) Nous avons abordé les différentes techniques de traitement des images médicales, y compris les méthodes d'acquisition, de prétraitement et de classification. Ces techniques sont essentielles pour améliorer la qualité des images et faciliter leur analyse.
- Les progrès récents de l'intelligence artificielle (IA) ont commencé à se répandre dans les domaines de santé consistant en des modules non linéaires capables d'apprendre automatiquement plusieurs niveaux de représentation à partir de données de grande dimension sans aucun besoin d'ingénierie explicite des caractéristiques par les humains. Les méthodes d'apprentissage en profondeur, en particulier les réseaux de neurones convolutifs (CNN) ont été examinés pour leur capacité à classifier et segmenter les images médicales. Ces modèles s'avèrent être de puissants outils pour la détection précoce et la classification précise du cancer de la peau.

Pour aboutir à cela nous avons fait les étapes suivantes :

- La première partie a été consacrée à une présentation de l'état de l'art sur le cancer de la peau, les différents traitements numériques et aux différents modèles de la classification des images médicales. Bien que les méthodes basées sur l'apprentissage automatique ou profond aient montré jusqu'à présent leur capacité prédictive prometteuse dans le domaine du diagnostic du cancer.

- La deuxième partie s'est intéressée aux réseaux de neurones convolutifs (CNN), pouvait être appliquée avec succès à la classification des images médicales, en particulier compte tenu des natures des ensembles de données disponibles dans ce domaine. Il semble qu'ils constituent une solution durable à ce problème. Notre travail montre que les réseaux de neurones convolutifs peuvent être appliqués efficacement dans la classification des images de la peau, même avec des ensembles de données limités. Nous avons programmé et testé divers algorithmes avec l'outil tel que Matlab, en étudiant l'influence de différents paramètres sur les résultats de la classification des images médicales. Les résultats obtenus sont excellents et montrent bien l'efficacité des CNN dans la classification.
- La troisième et la dernière partie ont été pour nous l'occasion de mettre à l'œuvre le CNN utilisé dans les parties précédentes. On a implémenté cette classification automatique sur des images médicales de la peau. Compte tenu de cette étude, nous avons retenu que la robustesse de ResNet18 donne des résultats satisfaisants dans les images de la peau au niveau de la prise de décision bénigne ou maligne.

Plusieurs améliorations pour la classification des images de la peau sont néanmoins envisageables.

V.2. Perspectives

Ce travail nous a ouvert de nouvelles perspectives sur l'utilisation des technologies avancées en imagerie médicale et en intelligence artificielle. L'application de ces technologies sur les images médicales offre des informations cruciales pour le diagnostic et le suivi des maladies, améliorant ainsi la prise de décision clinique. À l'avenir, l'intégration de techniques plus avancées d'apprentissage profond et d'IA, telles que les Réseaux Adversariaux Génératifs (GAN) et les techniques de transfert de connaissance, pourrait encore améliorer la précision et l'efficacité des diagnostics médicaux. En outre, l'application de ces technologies à d'autres domaines médicaux, comme la détection précoce d'autres types de cancers ou de maladies chroniques, présente des opportunités significatives pour le développement de systèmes de santé plus intelligents et plus efficaces.

BIBLIOGRAPHIE

- [1] Madhero88. (2006). Skin layers, Wikipedia, the free encyclopedia. Consulté le 10 mai 2012, Tiré de <http://en.wikipedia.org/wiki/File:Skinlayers.png>. Image avec le droit de copier, distribuer, transmettre et adapter.
- [2] Gray, H. (1918). Figure 941. In *Anatomy of the human body*. Philadelphia : Lea and Febiger. Consulté le 8 mai 2012, Tirée de <http://www.bartleby.com/107/illus941.html>. Image libre de droit.
- [3] <https://www.centre-chirurgie-dermatologique.fr/chirurgie-dermatologique/cancer-peau/carcinome/>
- [4] <https://www.centrethermalavene.com/>
- [5] Marghoob, A. A., Swindle, L. D., Moricz, C. Z. M., Sanchez Negron, F. A., Slue, B., Halpern, A. C. et Kopf, A. W. (2003). Instruments and new technologies for the in vivo diagnosis of melanoma. *J. Am. Acad. Dermatol.*, 49(5), pp. 777–797 Marghoob et al., 2003.
- [6] Betta, G., Di Leo, G., Fabbrocini, G., Paolillo, A. et Sommella, P. (2006). Dermoscopic image-analysis system: estimation of atypical pigment network and atypical vascular pattern. *IEEE Int. Workshop Med. Meas. Appl. Proc.*, 63–67.
- [7] Mogensen, M. et Jemec, G. B. E. (2007). Diagnosis of nonmelanoma skin cancer/keratinocyte carcinoma: a review of diagnostic accuracy of nonmelanoma skin cancer diagnostic tests and technologies. *Dermatol. Surg.*, 33(10), 1158–1174.
- [8] Andreassi, M. et Andreassi, L. (2007). Utility and limits of noninvasive methods in dermatology. *Expert Rev. Dermatol.*, 2(3), 249–255.
- [9] Thomas, L. (2018). *Dermatoscopie : De l'apprentissage à la maîtrise*.
- [10] <https://www.skinrepair.net.au/what-is-dermoscopy/>
- [11] De Giorgi, A. (2016). *Microscopie Confocale en Dermatologie*.
- [12] <https://www.rtl.be/350874/free-tags/microscope> .
- [13] Perrot, J. L. (2019). *Tomographie Optique Cohérente en Dermatologie*.
- [14] Elisa CINOTTI(ab), C. DONELLI(a), J.-L. PERROT(b,c) .

- [15] Bahadoran, P. (2017). Échographie Dermatologique.
- [16] https://fr.wikipedia.org/wiki/%C3%89chographie_haute_fr%C3%A9quence .
- [17] Dupont, J.-P. (2018). Spectroscopie d'Impédance Électrique pour les Applications Biomédicales. Elsevier.
- [18] Martin, C. (2019). Tomographie d'Impédance Électrique en Dermatologie.
- [19] <https://www.sciencedirect.com/science/article/abs/pii/S1279796021000772>
- [20] <https://www.skinrepair.net.au/what-is-dermoscopy/>
- [21] 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.
- [22] A. Mahbod, R. Ecker, I. Ellinger, Skin Lesion Classification Using Hybrid Deep Neural Networks, arXiv preprint arXiv:1702.08434, (2017).
- [23] K. Simonyan, A. Zisserman, Very deep convolutional networks for large-scale image recognition, arXiv preprint arXiv:1409.1556, (2014).
- [24] 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.
- [25] 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.
- [26] Chiter Yasmine et Hafiane Aicha ;Mémoire pour l'Obtention de Diplôme Master : en Informatique ;Apprentissage profond pour l'analyse et la classification d'imageries médicales ;2021/2022.
- [27] ull. Acad. Natle Méd., 2018, 202, no 7, 1665-1678, séance du 23 octobre 2018.
- [28] Jonathan Taquet, Claude Labit « Une Introduction à la Compression d'Images Médicales Volumiques», Rapport de recherche N° 7324, Institut National de Recherche en Informatique et en Automatique, 22 juin 2010, p68, ISSN 0249-6399.
- [29] FR www.sfr-radiologie.asso.fr & www.afib.asso.

- [30] Bushberg, J. T., Seibert, J. A., Leidholdt Jr, E. M., & Boone, J. M. (2011). The Essential Physics of Medical Imaging. Lippincott Williams & Wilkins.
- [31] Gonzalez, R. C., & Woods, R. E. (2018). Digital Image Processing. Pearson.
- [32] M. gonzales et R.C. wintz, "Digital image processing", Addison-wesley, 1977.
- [33] Benabdallah ali, "mise en œuvre d'une technique automatique de segmentation de sillons corticaux",Mémoire pour l'obtention du diplôme de Magister en Informatique2011.
- [34] M.sundaram et autre, "Histogram modified local contrast enhancement for mammogram images",Applied soft comuting, 2011 vol (11), pp (5809-5816).
- [36] [www.unit.eu/cours/; Transformation_ponctuelle_histogramme.pdf](http://www.unit.eu/cours/Transformation_ponctuelle_histogramme.pdf) vu le 15/04/2014.
- [37] He, H., & Garcia, E. A. (2009). Learning from imbalanced data. IEEE Transactions on Knowledge and Data Engineering, 21(9), 1263-1284.
- [38] http://fr.wikipedia.org/wiki/R%C3%A9solution_spatiale_des_images_matricielles vu le 15/04/2014.
- [39] Smith, J. (2020). "Méthodes de classification". Mémoire de maîtrise en Imagerie Médicale, Université ABC.
- [40] Johnson, J., Dou, Q., & Heng, P. A. (2020). "Classification des images et l'apprentissage machine». Dans Advances in Medical Imaging (pp. 45-62). Springer Publication scientifique.
- [41] Russell, S. J., & Norvig, P. (2016). "Artificial Intelligence: A Modern Approach" (3rd ed.). Prentice Hall.
- [42] Samuel, A. L. (1959). "Some Studies in Machine Learning Using the Game of Checkers". IBM Journal of Research and Development, 3(3), 210-229.
- [43] Marref, Nadia. (2013). "Apprentissage Incrémental & Machines à Vecteurs Supports." Mémoire de Magister en Informatique Industrielle, soutenu le 18 décembre 2013.
- [44] Boughaba, M., & Boukhris, B. (2017). L'apprentissage profond (Deep Learning) pour la classification et la recherche d'images par le contenu. Mémoire de Master Professionnel, Université Kasdi Merbah Ouargla .
- [45] Titre : Les différents algorithmes de Deep Learning. Type de document : Document en ligne Source : Scribd Lien : <https://fr.scribd.com/document/622933074/Les-differents-algorithmes-de-Deep-Learning>.

- [46] LOUAM ABDELHAK BILAL, « Deep Learning basé sur les méthodes de réduction pour la reconnaissance de visage », Mohamed Khaider de Biskra ,2019.
- [47] BELALEM ElhadjBrahim ,HAFIANEAbdelhakim, «Biometric System based on Neural Networks »,université Kasdi Merbah Ouargla 2019.
- [48] Goodfellow, Ian, Yoshua Bengio, et Aaron Courville. "Deep Learning." MIT Press, 2016.
- [49] Rafik BOUZELIFA , Seyfeddine ROUIMEL, « Reconnaissance des images avec les réseaux de neurones artificiels »,Université Mohammed Seddik Ben Yahia – Jijel,2019.
- [50] ZEGHBIB AYA, HABI NESRINE, « Amélioration des performances de La classification Des tumeurs mammaires à l'aide d'une méthode de Segmentation appropriée basée deep Learning) , MASTER ACADEMIQUE, Systèmes Distribués et Intelligence Artificielle, 2022/2023.