

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/2026

MEMOIRE DE FIN D'ÉTUDES DE MASTER ACADEMIQUE

Filière : Automatique.

Spécialité : Automatique et informatique Industrielle.

Thème

**Conception et développement d'un modèle de Deep Learning
pour la classification automatique du cancer de la peau.**

Présenté par :

M. TAHRI Bilel.

M. BERKANE Farouk.

Soutenu le 29/06/2026 à 10:00 devant le jury composé de :

Président : M. CHAAB Omar.

Université de Mostaganem

Examineur : M. BENAOUALI Mohamed.

Université de Mostaganem

Encadreur : Mme MEHIDI Aïcha.

Université de Mostaganem

Co-Encadreur : Mme MIMI Malika.

Université de Mostaganem

Année Universitaire : 2025/2026

REMERCIEMENTS

Je remercie avant tout Allah, le Tout-Puissant, de m'avoir accordé la force, la patience et le courage nécessaires pour mener à bien ce travail.

Nous exprimons notre profonde gratitude à notre encadrante Mme MEHIDI Aïcha ainsi qu'à notre co-encadrante Mme MIMI Malika pour leur aide précieuse, leur disponibilité constante, leur encadrement rigoureux et leurs conseils avisés qui nous ont accompagnés tout au long de la réalisation de ce mémoire.

Nous tenons à remercier chaleureusement les membres du jury, à savoir Monsieur CHAAB Omar et Monsieur BENAOUALI Mohamed, qui nous font l'honneur d'examiner ce travail et de l'enrichir par leurs remarques et leurs suggestions pertinentes.

Nous tenons également à remercier sincèrement tous nos enseignants pour la qualité de l'enseignement qu'ils nous ont dispensé tout au long de notre parcours universitaire, nous permettant ainsi d'acquérir une formation solide et efficace.

Nous tenons à exprimer notre sincère gratitude au Laboratoire de recherche Signaux et Systèmes (LSS) de l'Université de Mostaganem et à tous ses membres pour l'aide qu'ils nous ont apportée en termes d'équipement, d'espaces de travail, de commodités, de conseils, d'orientation et de suivi jusqu'à l'achèvement de nos projets de fin d'études master.

DÉDICACE

Je dédie ce modeste travail :

À mes chers parents, qui ont toujours été présents à mes côtés. Leur amour, leurs sacrifices, leurs encouragements et leur confiance ont constitué une source inestimable de motivation, pour tous les efforts qu'ils ont consentis afin de m'offrir les meilleures conditions de réussir.

À mes frères et sœurs, pour leur soutien moral, leur affection et leurs encouragements permanents. Leur présence et leur confiance en moi m'ont aidé à avancer avec détermination vers la réalisation de mes objectifs.

Enfin, j'adresse une pensée particulière à mon binôme et ami, Farouk Berkane, avec qui j'ai partagé cette expérience enrichissante.

M. Billel Tahri

DÉDICACE

Je dédie ce modeste travail :

À ma très chère mère, pour son amour inconditionnel, ses sacrifices, ses encouragements et son soutien tout au long de mon parcours.

À mon cher père, pour ses précieux conseils, sa confiance et tous les efforts qu'il a consentis pour mon éducation et ma réussite.

À mes frères et sœurs ainsi qu'à toute ma famille, pour leur affection et leur soutien permanent.

À mon binôme Tahri Bilel, avec qui j'ai partagé les efforts, les défis et les moments de travail durant la réalisation de ce projet.

À mes chers amis, particulièrement Belkhir Oussama, pour leur soutien moral, leur amitié sincère et leurs encouragements.

À toutes les personnes qui ont contribué, de près ou de loin, à la réalisation de ce travail.

M. BERKANE Farouk

Chapitre I :	page
Figure I.1 - Composants de la peau.	06
Figure I.2 - Type de cancer de la peau.	08
Figure I.3 - Carcinome basocellulaire.	09
Figure I.4 - Carcinome épidermoïde.	10
Figure I.5 - La kératose actinique	10
Figure I.6 - Le mélanome.	11
Figure I.7 - Principe de microscopie confocale à réflectance.	12
Figure I.8 - Tomographie par cohérence optique.	13
Figure I.9 - Échographie cutanée montrant les couches de la peau.	13
Figure I.10 - La dermoscopie pour détecter le cancer cutané.	14
 Chapitre II :	
Figure II.1 - Le schéma général de l'IA.	20
Figure II.2 - Les catégories d'apprentissage automatique.	20
Figure II.3 - Architecture globale d'apprentissage profond.	22
Figure II.4 - Architecture général d'un CNN.	23
Figure II.5 - Les couches de traitement d'un CNN.	24
Figure II.6 - Couche de convolution	25
Figure II.7 - Exemple d'une opération de Max Pooling de taille 2×2 .	25
Figure II.8 - Exemple d'une fonction d'activation ReLU.	26
Figure II.9 - Exemple d'une couche d'aplatissement.	26
Figure II.10 - Couche entièrement connectée.	27
Figure II.11 - Exemple d'application le Dropout sur un réseau neural.	28

Figure II.12 – Le principe de l'apprentissage par transfert (Transfer Learning). **30**

Chapitre III :

Figure III.1 - Schéma général de conception de système de la classification. **40**

Figure III.2 - Résultat de prétraitement des images de la peau : (a) image originale,
(b) image après le prétraitement. **45**

Figure III.3 - Architecture de modèle DenseNet169. **47**

Figure III.4 - Architecture de model VGG19. **49**

Figure III.5 - Évolution de la perte Loss et de l'Accuracy de l'entraînement et de
la validation du modèle DenseNet169. **60**

Figure III.6 - Évolution de la perte Loss et de l'Accuracy de l'entraînement et de
la validation du modèle VGG19. **61**

LISTE DES TABLEAUX

Chapitre III	page
Tableau III.1 - Résultats MSE et PSNR après le prétraitement des images.	44
Tableau III.2 - Comparaison des performances des modèles DenseNet169 et VGG19 utilisant les couches Flatten et Global Average Pooling (GAP).	56
Tableau III.3 - Performances des modèles DenseNet169 et VGG19 (couche GAP) pour différentes tailles de l'ensemble de test.	58
Tableau III.4 - Performances des modèles DenseNet169 et VGG19.	59

Adam	Adaptive Moment Estimation
AI / IA	Artificial Intelligence / Intelligence Artificielle
ADN	Acide Désoxyribonucléique
CNN	Convolutional Neural Network
CBS	Carcinome basocellulaire
DL	Deep Learning
DenseNet	Densely Connected Convolutional Network
OMS	Organisation Mondiale de la Santé
OCT	Optical Coherence Tomography
FN	False Negative
FP	False Positive
FPR	False Positive Rate
GAP	Global Average Pooling
GAN	Generative Adversarial Network
ISIC	International Skin Imaging Collaboration
K-NN	K-Nearest Neighbors
ML	Machine Learning
MSE	Mean Squared Error
NSI	National Cancer Institute
NHS	National Health Service
PSNR	Peak Signal to Noise Ratio
ReLU	Rectified Linear Unit
REM	Rayonnement électromagnétique
RGB	Red, Green, Blue
RCM	Reflectance Confocal Microscopy
SCC	Squamous cell carcinoma
SoftMax	Soft Maximum Fonction
SVM	Support Vector Machine
TALN	traitement automatique du langage naturel
TN	True Negative
TP	True Positive

UV	Ultraviolet
VGG19	Visual Geometry Group
VIH	Virus de l'Immunodéficience Humaine

La classification des lésions cutanées à partir d'images dermatologiques représente un domaine clé de l'aide au diagnostic médical assisté par ordinateur. Cependant, cette tâche est particulièrement complexe en raison de plusieurs facteurs, notamment la grande variabilité visuelle des lésions, la présence de bruit dans les images ainsi qu'un contraste parfois insuffisant. Ces difficultés rendent l'analyse manuelle moins fiable et limitent les performances des méthodes classiques de traitement d'images.

Dans ce contexte, ce travail propose le développement d'un système automatisé basé sur les techniques d'apprentissage profond afin d'améliorer la précision du diagnostic. L'approche adoptée repose principalement sur les réseaux de neurones convolutions (CNN) et le transfert d'apprentissage (Transfer Learning), permettant d'exploiter des modèles préentraînés pour extraire automatiquement des caractéristiques pertinentes et discriminantes à partir des images dermatologiques.

L'objectif de ce travail est de proposer un outil intelligent d'aide au diagnostic, capable d'assister les dermatologues dans l'analyse des images cutanées, tout en améliorant la rapidité, la précision et la détection précoce du cancer de la peau. Pour atteindre cet objectif, le système développé repose sur plusieurs étapes complémentaires. Dans un premier temps, les images sont prétraitées afin de réduire le bruit, d'améliorer le contraste et de normaliser les données, ce qui permet d'optimiser l'apprentissage du modèle. Ensuite, un modèle de classification est conçu et entraîné afin de distinguer les lésions bénignes des lésions malignes. Enfin, une phase d'évaluation est réalisée à l'aide de différentes métriques de performance afin de mesurer la fiabilité et l'efficacité du système.

Mots Clés : Transfert Learning, images de la peau, classification, réseaux de neurones convolutifs (CNN), VGG19, DenseNet169.

ABSTRACT

Computer-aided medical diagnosis for skin lesions relies heavily on classification based on dermatological images. There are multiple factors that make this task particularly complex, such as the wide visual variability of lesions, noise in the images, and sometimes insufficient contrast. The performance of conventional image processing methods is limited by these difficulties, which make manual analysis less reliable.

In this context, the proposed study is established on the development of an automated system based on deep learning techniques to improve diagnostic accuracy. Convolutional neural networks (CNNs) and transfer learning are the main factors of the approach, which enable pre-trained models to automatically extract relevant and discriminative features from dermatological images.

The purpose of this work is to propose an intelligent diagnostic aid tool, capable of assisting dermatologists in the analysis of skin images, whilst improving the speed, accuracy and early detection of skin cancer. To achieve this objective, the developed system is based on several complementary stages. Firstly, the images are pre-processed to reduce noise, improve contrast and normalize the data, thereby optimizing the model's learning. Next, a classification model is designed and trained to distinguish between benign and malignant lesions. Finally, an evaluation phase is conducted by utilizing various performance metrics to assess the system's reliability and effectiveness.

Keywords: Transfer learning, skin images, classification, convolutional neural networks (CNN), VGG19, DenseNet169.

يُعدّ تصنيف الأمراض من الصور الجلدية مجالاً رئيسياً في التشخيص الطبي بمساعدة الحاسوب. إلا أن هذه المهمة بالغة التعقيد نظراً لعدة عوامل، لا سيما التباين البصري الكبير بين الخلفية ومجال الاهتمام في الصور، وأحياناً عدم كفاية التباين هذه الصعوبات تجعل التحليل اليدوي أقل موثوقية وتحدّ من أداء طرق معالجة الصور التقليدية.

في هذا السياق، يقترح هذا العمل تطوير نظام آلي قائم على تقنيات التعلّم العميق لتحسين دقة التشخيص. يعتمد النهج المُعتمد بشكل أساسي على الشبكات العصبية الالتفافية والتعلّم النقلي، مما يسمح باستخدام نماذج مُدرّبة مسبقاً لاستخراج السمات ذات الصلة والمميزة من الصور الجلدية تلقائياً.

يهدف هذا العمل إلى توفير أداة تشخيصية ذكية قادرة على مساعدة أطباء الجلد في تحليل صور الجلد، مع تحسين سرعة ودقة الكشف المبكر عن سرطان الجلد. ولتحقيق هذا الهدف، يعتمد النظام المُطوّر على عدة خطوات مُتكاملة. أولاً، تُعالج الصور مسبقاً لتقليل التشويش، وتحسين التباين، وتوحيد البيانات، مما يُحسّن عملية تعلم النموذج. ثانياً، يُصمّم نموذج تصنيف ويُدرّب للتمييز بين الآفات الحميدة والخبيثة. أخيراً، تُجرى مرحلة تقييم باستخدام مقاييس أداء متنوعة لقياس موثوقية النظام وكفاءته.

كلمات مفتاحية: التعلم بالنقل، صور الجلد، التصنيف، الشبكات العصبية الالتفافية (CNN)، VGG19،

DenseNet169.

TABLE DES MATIÈRES

Liste des figures	A
Liste des tableaux	C
Abréviation	D
Résumé	F
Abstract	G
Résumé en arabe	H

INTRODUCTION GÉNÉRALE 01

CHAPITRE I : MISE AU POINT SUR LE CANCER DE LA PEAU (ÉTAT DE L'ART)

I.1. Introduction	05
I.2. Définition du terme "Peau"	05
I.3. Composants de la peau	06
I.3.1. L'épiderme	06
I.3.2. Derme	07
I.3.3. Hypoderme	07
I.4. Cancer de la peau	07
I.5. Type de cancer de la peau	08
I.5.1. Carcinome	08
I.5.1.1. Carcinome basocellulaire (Carcinome basocellulaire CBC)	09
I.5.1.2. Carcinome épidermoïde (Squamous-Cell Carcinoma SCC)	09
I.5.2. La Kératose acnitique	10
I.5.3. Mélanome	10
I.6. Techniques d'imagerie du cancer de la peau	11
I.6.1. Microscopie confocale à réflectance (Reflectance confocal microscopy RCM)	11
I.6.2. Tomographie par cohérence optique (Optical Coherence Tomography OCT)	12
I.6.3. Échographie	13
I.6.4. Dermoscopie	13
I.7. Les facteurs de risque	14
I.7.1. Exposition aux rayons ultraviolets (UV)	14

I.7.2. Antécédents familiaux	14
I.7.3. Peau claire	15
I.7.4. Exposition professionnelle	15
I.7.5. Antécédents de coups de soleil graves	15
I.7.6. Immunité affaiblie	15
I.7.7. Exposition aux radiations	15
I.8. Le repérage des cancers de la peau	16
I.9. Signes et symptômes possibles du cancer de la peau	16
I.10. Conclusion	17

CHAPITRE II : CLASSIFICATION D'IMAGES MEDICALES APPLIQUEE AU DIAGNOSTIC DES LESIONS CUTANEEES

II.1. Introduction	19
II.2. Intelligence Artificielle (IA)	19
II.2.1. Définitions	19
II.2.2. Machine Learning (Apprentissage Automatique)	20
II.2.2.1. Définition	20
II.2.2.2. Apprentissage supervisé	21
II.2.2.3. Apprentissage non supervisé	21
II.2.2.4. Apprentissage par renforcement	21
II.2.3. Deep Learning (Apprentissage Profond)	22
II.2.3.1. Convolutional Neural Networks (CNN)	22
II.2.3.1.1. Typologie des architectures des réseaux de neurones convolutifs	23
II.2.3.1.2. Architecture des réseaux de neurones convolutifs	24
II.2.3.2. Autres approches du Deep Learning	29
II.2.3.3. Apprentissage par transfert (Transfer Learning)	29
II.2.3.4. Le sur-ajustement	31
II.3. Classification des images de la peau	31
II.3.1. Définitions	31
II.3.2. Les caractéristiques des images de la peau	31
II.3.2.1. Texture	32
II.3.2.2. Couleur	32
II.3.2.3. Lésions cutanées	32

II.3.2.4. Vascularisation	32
II.3.2.5. Épaisseur	33
II.3.2.6. Hydratation	33
II.3.2.7. Élasticité	33
II.3.2.8. Texture de surface	33
II.3.3. Types de classifications	33
II.3.2.1. Classification Binaire	34
II.3.2.2. Classification Multiclasses	34
II.3.2.3 Classification multi-label	34
II.3.4. Problématique	34
III.4. Conclusion	35

CHAPITRE III : MISE EN ŒUVRE DU SYSTEME DE CLASSIFICATION

III.1. Introduction	37
III.2. Environnement de développement	37
III.2.1. Outil de développement : PYTHON	38
III.2.1.1. Définition	38
III.2.2. Base de données	38
III.3. Conception et implémentation d'un système de classification	39
III.3.1. Objectif	39
III.3.2. Schéma général de conception	39
III.3.2.1. Prétraitement des images	39
III.3.2.1.1. Importance du prétraitement	40
III.3.2.1.2. Correction des artefacts	41
III.3.2.1.3. Normalisation des intensités	41
III.3.2.1.4. Réduction du bruit	42
III.3.2.1.5. Évaluation de l'efficacité du processus de prétraitement	42
III.3.2.2. Détection et classification des images des peaux	46
III.3.2.2.1. Les architectures du DenseNet169 & VGG19 : Modèles (CNN)	46
III.3.2.2.1.1. Le modèle DenseNet169	46
III.3.2.2.1.2. Le modèle VGG19	49
III.3.2.2.2. Les métriques d'évaluation de la classification	50
III.4. Résultats expérimentaux	53
III.4.1. Présentation des résultats	53

III.4.2. Analyse et discussion	54
III.5. Conclusion	62

CHAPITRE IV : CONCLUSION GÉNÉRALE

IV.1. Récapitulatif	64
IV.2. Perspectives	65

BIBLIOGRAPHIE	66
----------------------	----

INTRODUCTION GÉNÉRALE

Le cancer de la peau constitue aujourd'hui l'un des défis les plus importants en matière de santé publique à travers le monde. Le nombre de personnes touchées par cette maladie augmente continuellement, ce qui suscite une grande inquiétude au sein de la communauté médicale et chercheurs scientifique. Cette pathologie regroupe plusieurs formes de tumeurs cutanées, dont certaines peuvent évoluer de manière agressive et entraîner des complications graves lorsqu'elles ne sont pas prises en charge à temps.

Face à cette situation, le dépistage et le diagnostic précoce occupent une place primordiale. Une identification rapide des lésions suspectes permet non seulement d'améliorer l'efficacité des traitements, mais aussi d'augmenter considérablement les chances de guérison des patients. De plus, une détection précoce contribue à limiter l'évolution de la maladie, à réduire les interventions médicales lourdes et à diminuer le taux de mortalité associé au cancer de la peau. Ainsi, le renforcement des méthodes de diagnostic et la sensibilisation à l'importance du suivi dermatologique représentent aujourd'hui des axes essentiels dans la lutte contre cette maladie.

Le diagnostic des maladies cutanées s'appuie principalement sur l'examen clinique effectué par le dermatologue, auquel peuvent s'ajouter des examens complémentaires tels que l'imagerie médicale ou l'analyse histopathologiques. Néanmoins, cette approche repose largement sur les compétences et l'expérience du spécialiste, ce qui peut parfois entraîner des variations dans l'interprétation des lésions. En outre, la grande diversité des lésions cutanées, qu'elles soient de forme, de couleur, de texture ou de taille, rend leur identification et leur classification particulièrement délicates. Dans ce contexte, l'utilisation des technologies basées sur l'intelligence artificielle est de plus en plus envisagée, car elles offrent des outils performants qui peuvent aider les professionnels de santé dans l'analyse et le diagnostic.

En dermatologie, les images de la peau constituent une source d'informations particulièrement riche pour l'analyse des lésions cutanées. Elles permettent d'observer des éléments visuels essentiels, comme la forme, la symétrie, la pigmentation, les contours et la

texture. Toutefois, la qualité de ces images peut varier considérablement en fonction des conditions d'acquisition, de l'éclairage, du contraste ou encore de la présence de bruit. Une étape de prétraitement s'avère ainsi indispensable pour améliorer la qualité visuelle des images et optimiser les performances des modèles de classification. L'amélioration du contraste, en particulier, permet de mettre en évidence les détails pertinents des lésions.

L'intelligence artificielle occupe aujourd'hui une place importante dans le domaine médical, notamment pour assister au diagnostic des maladies cutanées. Face à la complexité et à la diversité des lésions cutanées, les techniques d'apprentissage profond permettent d'améliorer la précision de l'analyse et de la classification des images médicales. Parmi ces techniques, les réseaux de neurones convolutifs (CNN) offrent des performances supérieures aux méthodes classiques de traitement et de classification d'images.

Ce projet de fin d'études s'inscrit dans le cadre de l'utilisation de Deep Learning pour la détection automatique du cancer de la peau. Son objectif est de développer un modèle de classification des lésions cutanées à l'aide de techniques de transfert d'apprentissage, en exploitant des architectures performantes telles que VGG19 et DenseNet169. Le travail porte sur la mise en place d'un système complet permettant d'analyser et de classer les images dermatologiques en lésions bénignes ou malignes, afin de proposer aux professionnels de santé un outil d'aide au diagnostic plus rapide et plus précis.

Ce manuscrit est constitué de trois chapitres organisés comme suit :

- Dans le premier chapitre de ce travail, nous présentons les bases nécessaires à la compréhension du cancer de la peau. Ce chapitre introduit la structure de la peau, définit le cancer cutané et ses principaux types, puis aborde les différentes techniques d'imagerie utilisées pour son diagnostic. Il présente également les principaux facteurs de risque ainsi que les signes permettant de repérer la maladie. Enfin, il souligne l'importance de la détection précoce dans la prise en charge du cancer de la peau.
- Au sein du deuxième chapitre, nous présentons les concepts fondamentaux de l'intelligence artificielle, en mettant l'accent sur la Machine Learning et le Deep Learning, ainsi que sur les réseaux de neurones convolutifs (CNN) et leur fonctionnement. Ce chapitre aborde également les principales méthodes d'apprentissage et les techniques permettant d'améliorer les performances des modèles. Enfin, il

introduit la classification des images de la peau, ses caractéristiques et ses enjeux, afin de préparer leur application dans le diagnostic des maladies cutanées.

- Au cours du troisième chapitre, nous présentons la mise en œuvre des approches proposées, notamment DenseNet169 et VGG19, ainsi que les expérimentations réalisées et l'analyse des résultats obtenus. L'évaluation du prétraitement est effectuée à l'aide de mesures telles que le rapport signal sur bruit de crête (PSNR) et l'erreur quadratique moyenne (MSE). Pour la phase de classification, différentes métriques sont utilisées afin d'apprécier les performances du modèle.

Enfin, le mémoire se termine par une conclusion générale accompagnée des perspectives de recherche envisagées.

CHAPITRE I

MISE AU POINT SUR LE CANCER DE LA PEAU

Le cancer de la peau représente aujourd'hui un important problème de santé publique en raison de son augmentation croissante à travers le monde. La détection précoce joue un rôle essentiel dans l'amélioration des chances de traitement et de survie, ce qui souligne l'importance du dépistage et des techniques d'imagerie médicale.

Dans ce chapitre, nous présentons les notions fondamentales liées au cancer cutané, notamment la structure de la peau, les différents types de lésions et de cancers cutanés, ainsi que leur classification. Nous abordons également les principales méthodes d'imagerie utilisées pour le diagnostic, les facteurs de risque et les signes cliniques permettant d'identifier la maladie. Cette illustration vise à mieux comprendre la problématique étudiée et à introduire les méthodes de détection et de classification des anomalies dans les images médicales.

I.1. Introduction

Depuis plusieurs années, le cancer de la peau représente un problème de santé de plus en plus important dans le monde. Le nombre de personnes touchées ne cesse d'augmenter, ce qui attire l'attention des médecins et des chercheurs. Dans ce contexte, la détection précoce joue un rôle essentiel, car elle permet d'identifier les lésions suspectes à temps, avant qu'elles ne deviennent plus dangereuses. Plus le diagnostic est réalisé tôt, plus les traitements sont efficaces et les chances de guérison sont élevées.

Le cancer de la peau regroupe un ensemble de proliférations malignes développées à partir de différents types cellulaires du tégument. Les formes les plus courantes sont les carcinomes cutanés, essentiellement bas cellulaires et épidermoïdes, alors que le mélanome est moins fréquent mais nettement plus redouté du fait de sa capacité à diffuser à distance. Cette hétérogénéité impose une approche différenciée en matière de description anatomopathologique, de repérage clinique et de prise en charge [1], [2].

L'intérêt scientifique et médical porté à cette pathologie s'explique par son poids épidémiologique, mais aussi par la possibilité d'améliorer fortement le pronostic grâce au diagnostic précoce. Les données institutionnelles et cliniques montrent qu'une surveillance attentive de la peau, associée au recours à des outils d'imagerie adaptés, permet de repérer plus tôt les lésions suspectes et d'orienter plus efficacement la décision médicale [3].

I.2. Définition du terme "Peau"

La peau est l'organe le plus étendu de l'organisme humain et représente sa principale interface avec le milieu extérieur. Elle assure une fonction de barrière physique et biologique de premier ordre. Sur le plan anatomique, elle recouvre l'ensemble de la surface corporelle et protège l'organisme contre les agents microbiens, les traumatismes, la perte hydrique et les agressions liées au rayonnement ultraviolet [1], [4].

Au-delà de cette fonction protectrice, la peau possède également des fonctions sensibles, immunologiques, endocrines et exocrines. Elle participe à la perception de la douleur, de la température et du toucher, intervient dans la production de vitamine D, sécrète différentes substances comme le sébum et la sueur, et contribue au maintien de l'homéostasie thermique. Cette richesse fonctionnelle explique l'importance des conséquences locales et systémiques pouvant découler d'une atteinte cutanée chronique ou néoplasique [4].

I.3. Composants de la peau

La peau est classiquement décrite comme un ensemble organisé en trois couches : l'épiderme, le derme et l'hypoderme. Chacune d'elles présente une structure particulière et participe, de manière complémentaire, à la protection, au soutien, à la nutrition, à la sensibilité et à l'adaptation mécanique de la surface cutanée (comme illustré dans la figure I.1). Cette organisation stratifiée est également essentielle pour comprendre la localisation d'origine de nombreuses lésions tumorales [2].




Figure I.1- Composants de la peau.

I.3.1. L'épiderme

L'épiderme correspond à la couche la plus superficielle. Il forme une barrière imperméable qui limite les pertes en eau et s'oppose à la pénétration de nombreux agents extérieurs. Il est principalement constitué de kératinocytes en renouvellement continu, mais comporte aussi des mélanocytes, responsables de la production de mélanine, pigment jouant un rôle protecteur contre les rayons ultraviolets (UV) [1], [4].

Sur le plan oncologique, l'épiderme revêt une importance particulière puisque plusieurs cancers cutanés y prennent naissance. Les carcinomes sont liés aux kératinocytes, tandis que le mélanome dérive des mélanocytes. Les altérations de l'ADN induites par l'exposition solaire ou par d'autres facteurs de risque peuvent ainsi amorcer un processus progressif de transformation maligne au sein de cette couche [1], [5].

I.3.2. Derme

Le derme, situé sous l'épiderme, est un tissu conjonctif riche en fibres de collagène et d'élastine. Il contient également des vaisseaux sanguins, des vaisseaux lymphatiques, des follicules pileux, des glandes sudoripares et sébacées ainsi que de nombreuses terminaisons nerveuses. Cette couche assure le soutien mécanique de la peau, sa résistance et une partie essentielle de sa nutrition [4].

Dans l'étude du cancer cutané, l'atteinte du derme est capitale. L'invasion dermique marque souvent une étape évolutive importante, en particulier pour le mélanome, dont le risque de dissémination dépend en grande partie de l'épaisseur tumorale au moment de l'exérèse. Ainsi, la profondeur d'extension constitue un élément pronostique majeur [5].

I.3.3. Hypoderme

L'hypoderme, également appelé tissu sous-cutané, constitue la couche la plus profonde du tégument cutané. Il est principalement formé de tissu adipeux et de tissu conjonctif, assurant plusieurs fonctions essentielles telles que l'isolation thermique, le stockage des réserves énergétiques et la protection mécanique de l'organisme [4]. Bien qu'il ne soit pas systématiquement considéré comme une composante histologique de la peau, il joue un rôle important dans la continuité fonctionnelle des tissus cutanés. En pathologie tumorale, l'atteinte de l'hypoderme peut indiquer une extension locale plus avancée de la lésion, ce qui lui confère une importance clinique particulière dans l'évaluation de certaines tumeurs cutanées [3].

I.4. Cancer de la peau

Le cancer de la peau correspond à une prolifération anarchique de cellules cutanées qui ont subi des altérations génétiques et biologiques les rendant anormales. Ce processus, appelé cancérogenèse cutanée, est généralement progressif et résulte de l'accumulation de dommages au niveau de l'ADN, souvent induits par une exposition répétée ou excessive aux rayonnements ultraviolets. Ces altérations touchent des gènes essentiels impliqués dans la régulation du cycle cellulaire, notamment ceux contrôlant la prolifération, la différenciation et l'apoptose, ce qui entraîne une perte des mécanismes normaux de contrôle de la croissance cellulaire [1].

Sur le plan épidémiologique, les cancers cutanés comptent parmi les cancers les plus fréquents dans le monde. Selon l'Organisation mondiale de la santé (OMS), l'exposition

excessive aux rayons ultraviolets est responsable d'environ 1,2 million de nouveaux cas de cancers cutanés non mélanocytaires et de 325 000 cas de mélanome en 2020. Bien que les carcinomes cutanés soient les plus fréquents, le mélanome reste la forme la plus grave en raison de son fort potentiel d'invasion des tissus et de sa capacité à former des métastases, ce qui en fait une pathologie particulièrement préoccupante en termes de mortalité [1], [6].

I.5. Type de cancer de la peau

Les cancers de la peau regroupent principalement le carcinome basocellulaire, le carcinome épidermoïde et le mélanome. Ces tumeurs malignes se développent à partir des différentes cellules cutanées et peuvent atteindre les diverses couches de la peau. Leur classification ainsi que l'évaluation de leur extension sont essentielles pour le diagnostic, le pronostic et le choix du traitement [1]. La figure I.2 illustre les principaux types de cancers cutanés, ainsi que leur localisation et leur profondeur d'extension au sein des différentes couches de la peau.




Figure I.2 - Type de cancer de la peau.

I.5.1. Carcinome

Le terme carcinome désigne ici les tumeurs malignes développées à partir des kératinocytes. Les carcinomes cutanés surviennent surtout sur les zones de photo-exposition chronique, telles que le visage, le cuir chevelu, le cou et le dos des mains. Leur fréquence élevée contraste avec une agressivité généralement moindre que celle du mélanome, même si certains sous-types peuvent être localement destructeurs ou, plus rarement, métastatiques [7].

I.5.1.1. Carcinome basocellulaire (Carcinome basocellulaire CBC)

Le carcinome basocellulaire représente la forme la plus fréquente des cancers cutanés (comme présenté dans la figure I.3). Selon DermNet, il s'agit d'une tumeur kératinocytaire fréquente, à croissance lente et à caractère localement invasif. Sur le plan clinique, il se manifeste généralement par une plaque ou un nodule nacré, rosé ou pigmenté, pouvant être associé à des télangiectasies, une ulcération ou des saignements spontanés.

Son potentiel métastatique demeure très faible, ce qui confère à cette tumeur un pronostic souvent favorable lorsqu'elle est diagnostiquée et prise en charge précocement. Toutefois, en l'absence de traitement, elle peut provoquer des destructions locales importantes, notamment au niveau des régions faciales. Ainsi, malgré la rareté des métastases, le carcinome basocellulaire ne doit pas être considéré comme une tumeur bénigne [8].



Figure I.3 - Carcinome basocellulaire.

I.5.1.2. Carcinome épidermoïde (Squamous-Cell Carcinoma SCC)

Le carcinome épidermoïde cutané dérive des kératinocytes et apparaît fréquemment sur une peau chroniquement exposée au soleil. Il peut aussi se développer à partir d'une kératose actinique ou d'un carcinome in situ. Sur le plan clinique, il se manifeste souvent par un nodule kératosique irrégulier ou une plaque érythémateuse indurée, volontiers ulcérée (voir la figure I.4). Contrairement au carcinome basocellulaire, le carcinome épidermoïde possède un véritable potentiel métastatique, même si celui-ci reste globalement peu fréquent. Ce risque augmente lorsque la tumeur est plus profonde, peu différenciée ou diagnostiquée tardivement. Sa reconnaissance rapide est donc essentielle dans la stratégie de prise en charge [9].



Figure I.4 - Carcinome épidermoïde.

I.5.2. La kératose actinique

La kératose actinique est une lésion cutanée liée à une exposition chronique au soleil. Elle apparaît généralement sous la forme d'une plaque rugueuse, squameuse ou kératosique sur une peau photo-endommagée (ainsi que l'indique la figure I.5). Selon DermNet, elle est considérée comme une lésion précancéreuse et peut être interprétée comme un stade précoce du carcinome épidermoïde cutané.

Le risque de transformation d'une kératose actinique isolée en carcinome épidermoïde reste relativement faible. Toutefois, la présence de lésions multiples reflète une exposition solaire importante et une fragilité cutanée accrue. Certains signes cliniques, tels qu'un épaissement, une douleur, une ulcération ou une augmentation de taille, peuvent évoquer une évolution vers une forme maligne [10].



Figure I.5 - La kératose actinique.

I.5.3. Mélanome

Le mélanome est une tumeur maligne issue des mélanocytes. Bien qu'il soit moins fréquent que les carcinomes, il constitue la forme la plus sévère du cancer cutané. Il peut

apparaître sur une peau saine ou sur une lésion pigmentée préexistante, et son aspect clinique est variable : macule asymétrique, lésion polychrome, contour irrégulier ou forme nodulaire d'évolution rapide (comme visible sur la figure I.6).

Sa gravité tient à sa capacité de propagation vers les ganglions lymphatiques, la peau, le cerveau, les poumons, le foie ou d'autres organes. Les données cliniques montrent que le risque de diffusion dépend largement de l'épaisseur tumorale au moment de l'exérèse. Cela justifie l'insistance portée au dépistage précoce et à la surveillance des lésions pigmentées suspectes [5], [6].



Figure I.6 - Le mélanome.

I.6. Techniques d'imagerie du cancer de la peau

L'imagerie cutanée non invasive occupe une place croissante dans le diagnostic et la surveillance des lésions suspectes. Elle ne remplace pas l'analyse histopathologique après biopsie, qui demeure l'étalon de référence, mais elle permet d'améliorer le tri diagnostique, de réduire certaines biopsies inutiles et d'apporter des arguments morphologiques utiles à la décision clinique [3].

I.6.1. Microscopie confocale à réflectance (RCM)

La microscopie confocale à réflectance est une technique d'imagerie optique en temps réel offrant une résolution quasi cellulaire dans les couches superficielles de la peau (voir la figure I.7). La littérature récente souligne sa haute sensibilité diagnostique, sa capacité à cartographier les marges tumorales et son intérêt dans le suivi thérapeutique ou la surveillance des récidives.

Ses limites tiennent principalement à sa profondeur de pénétration restreinte, à la durée parfois plus longue de l'acquisition, au coût des équipements et à la nécessité d'une

formation spécifique pour l'interprétation. Malgré cela, elle représente un outil particulièrement utile pour les lésions pigmentées difficiles ou douteuses [3].




Figure I.7 – Principe de microscopie confocale à réflectance.

I.6.2. Tomographie par cohérence optique (OCT)

La tomographie par cohérence optique (OCT) est une technique d'imagerie non invasive qui permet d'obtenir des images en coupe des tissus cutanés à partir de la réflexion de la lumière (comme indiqué dans la figure I.8). Elle offre une exploration plus profonde que la microscopie confocale à réflexion et permet une analyse détaillée de l'architecture des lésions, en particulier pour apprécier l'épaisseur tumorale, les limites lésionnelles et certaines caractéristiques structurelles de la peau.

Cette méthode présente l'avantage d'être rapide, indolore et réalisable en consultation, sans préparation particulière. Elle est donc utile dans le suivi et l'évaluation des lésions cutanées. Toutefois, sa résolution reste inférieure à celle de la microscopie confocale, ce qui limite l'analyse fine au niveau cellulaire. De plus, ses performances peuvent être réduites en présence de lésions hyperkératosiques ou dans la distinction précise entre certaines tumeurs cutanées proches sur le plan morphologique [3].



Figure I.8– Tomographie par cohérence optique.

I.6.3. Échographie

L'échographie cutanée, en particulier à haute fréquence, permet d'explorer l'épaisseur d'une lésion, ses rapports avec les structures sous-jacentes et parfois sa vascularisation (tel qu'illustré dans la figure I.9). Son intérêt augmente dans l'évaluation pré thérapeutique des tumeurs plus épaisses, ainsi que dans le suivi de certaines lésions évolutives.

Son principal avantage réside dans sa profondeur de pénétration supérieure à celle des techniques optiques. Toutefois, sa résolution est plus faible, l'interprétation reste dépendante de l'opérateur et la taille tumorale peut être surestimée dans certains cas. Elle est donc surtout pertinente comme outil complémentaire [3].



Figure I.9 – Échographie cutanée montrant les couches de la peau.

I.6.4. Dermoscopie

La dermoscopie est une technique d'examen non invasive largement utilisée en dermatologie. Elle permet de visualiser des structures cutanées non perceptibles à l'œil nu grâce à un système optique grossissant associé à un éclairage spécifique (voir figure I.10). En pratique, elle facilite l'identification de critères diagnostiques en faveur du mélanome, du carcinome basocellulaire ainsi que d'autres lésions pigmentées ou non pigmentées.

Cependant, la performance de cet outil dépend fortement de l'expérience et des compétences de l'examineur. Cette variabilité d'interprétation a encouragé le développement de solutions numériques et de systèmes d'aide au diagnostic, visant à améliorer la précision et la reproductibilité des analyses dermoscopiques [2].



Figure I.10 – La dermoscopie pour détecter le cancer cutané.

I.7. Les facteurs de risque

Le risque de cancer cutané résulte généralement de l'interaction entre facteurs environnementaux, phénotypiques, génétiques et médicaux. La littérature institutionnelle converge pour identifier l'exposition aux UV comme facteur central, auquel s'ajoutent la sensibilité cutanée individuelle, les antécédents familiaux, l'immunodépression et certaines expositions professionnelles ou radiologiques [1], [6] et [7].

I.7.1. Exposition aux rayons ultraviolets (UV)

L'exposition aux rayonnements ultraviolets représente le facteur de risque principal des cancers de la peau. Les UV endommagent l'ADN cellulaire et favorisent l'accumulation de mutations susceptibles d'induire une transformation maligne. L'OMS et l'American Cancer Society soulignent que le soleil constitue la source principale d'UV, tandis que les dispositifs de bronzage artificiel en représentent une autre source évitable.

I.7.2. Antécédents familiaux

Les antécédents familiaux, surtout pour le mélanome, augmentent le niveau de risque. L'American Cancer Society indique qu'environ une personne sur dix atteintes de mélanome rapporte une histoire familiale de la maladie. Cette majoration du risque peut refléter des facteurs génétiques transmis, des habitudes d'exposition communes ou l'association des deux.

I.7.3. Peau claire

Les sujets ayant une peau claire, des cheveux roux ou blonds, des yeux clairs et une tendance aux coups de soleil présentent un risque plus élevé. Cette vulnérabilité s'explique par une moindre protection conférée par la mélanine. Les sources institutionnelles rappellent néanmoins que les personnes à peau plus foncée ne sont pas totalement protégées et peuvent aussi développer des cancers cutanés.

I.7.4. Exposition professionnelle

Certaines activités professionnelles augmentent l'exposition cumulative au soleil. Les travailleurs en extérieur sont particulièrement concernés, notamment lorsqu'ils exercent pendant de longues heures sans protection adaptée. L'OMS mentionne explicitement l'augmentation du risque de cancers cutanés non mélanocytaires chez les travailleurs exposés de façon professionnelle au rayonnement solaire.

I.7.5. Antécédents de coups de soleil graves

Les coups de soleil sévères, surtout lorsqu'ils surviennent durant l'enfance ou l'adolescence, sont fortement associés au risque ultérieur de mélanome. Les données de l'American Cancer Society indiquent que certains profils de mélanome sont liés à des expositions intermittentes intenses et à des brûlures solaires répétées.

I.7.6. Immunité affaiblie

Une immunité altérée favorise également la survenue de cancers cutanés. Les patients transplantés, les personnes vivant avec le VIH ou celles recevant des traitements immunosuppresseurs présentent un risque majoré de mélanome et de cancers kératinocytaire. De plus, ces tumeurs peuvent évoluer plus rapidement et se révéler plus difficiles à traiter dans ce contexte.

I.7.7. Exposition aux radiations

L'exposition à certaines radiations, notamment après une radiothérapie, peut accroître le risque de cancer cutané dans la zone irradiée. L'American Cancer Society cite également l'exposition à certains agents chimiques et certaines situations inflammatoires chroniques comme facteurs supplémentaires, ce qui montre le caractère multifactoriel de la cancérogenèse cutanée.

I.8. Le repérage des cancers de la peau

Le repérage des cancers de la peau repose sur l'auto-observation régulière de la peau par le patient, complétée par un examen clinique réalisé par un professionnel de santé. Les recommandations de dépistage insistent sur la surveillance de toute nouvelle lésion, de toute modification inhabituelle d'un grain de beauté, ou encore d'une plaie persistante qui ne cicatrise pas.

Pour les lésions pigmentées, la règle ABCDE constitue un outil simple d'aide à la détection précoce : A pour l'asymétrie de la lésion, B pour l'irrégularité des bords, C pour la variation ou l'hétérogénéité des couleurs, D pour le diamètre généralement supérieur à 6 mm, et E pour l'évolution dans le temps (changement d'aspect, de taille ou de forme).

Selon le National Cancer Institute, cette règle permet de guider l'évaluation des lésions suspectes. Le NHS souligne également que des signes associés tels que douleur, prurit, croûtes ou saignements inhabituels doivent alerter et conduire à une consultation. Toutefois, l'auto-surveillance ne remplace pas l'examen médical, qui peut être complété par une dermoscopie ou un avis spécialisé [2], [11].

I.9. Signes et symptômes possibles du cancer de la peau

Les signes cliniques varient selon le type de tumeur. Dans le mélanome, les modifications de taille, de forme, de couleur ou de relief d'une lésion pigmentée sont particulièrement évocatrices. Une lésion asymétrique, aux contours irréguliers, présentant plusieurs teintes ou évoluant rapidement doit être considérée avec attention.

Le NHS (National Health Service) est le système public de santé du Royaume-Uni. Il fournit des recommandations médicales et des informations de référence destinées à la population et aux professionnels de santé, notamment dans le domaine du dépistage et des signes d'alerte des maladies.

Selon le NHS, plusieurs signes cutanés doivent attirer l'attention, tels que la douleur, le prurit, l'inflammation, les saignements, la présence de croûtes persistantes, l'apparition d'une lésion cutanée inhabituelle ou encore une bande pigmentée sous un ongle sans cause traumatique. Concernant les carcinomes, les manifestations peuvent inclure une ulcération, un nodule kératosique, une plaque infiltrée ou une plaie qui ne cicatrise pas [11].

I.10. Conclusion

Avant de présenter la partie technique, il est essentiel de bien maîtriser les aspects médicaux du sujet. Le cancer de la peau regroupe des pathologies de gravité variable, allant des carcinomes, les plus fréquents, au mélanome, le plus sévère sur le plan pronostique. Les progrès des techniques d'imagerie non invasives ont amélioré le dépistage et l'orientation diagnostique, mais l'histologie reste la référence. La prévention, l'éducation et la détection précoce des signes suspects jouent un rôle essentiel dans la lutte contre ces cancers.

CHAPITRE II

CLASSIFICATION D'IMAGES MEDICALES APPLIQUEE AU DIAGNOSTIC DES LESIONS CUTANÉES

Ce chapitre présente les bases de la classification des images médicales pour le diagnostic des lésions cutanées à l'aide de l'intelligence artificielle, de la machine learning et du Deep Learning. Il met l'accent sur les réseaux de neurones convolutifs (CNN), capables d'extraire automatiquement des caractéristiques importantes des images dermatologiques.

Le chapitre décrit également les architectures CNN, les techniques d'optimisation et de régularisation pour améliorer les performances et réduire le sur-apprentissage. Enfin, il aborde les différents types de classification des lésions ainsi que les principaux défis liés à la variabilité et à la complexité des données médicales, tout en soulignant l'importance de ces méthodes dans l'aide au diagnostic dermatologique.

II.1. Introduction

La classification d'images médicales constitue aujourd'hui un axe majeur de recherche en intelligence artificielle appliquée à la santé. Dans le domaine de la dermatologie, elle joue un rôle particulièrement important dans l'aide au diagnostic des lésions cutanées, notamment pour la détection précoce des cancers de la peau. L'intérêt de cette approche repose sur la capacité des algorithmes modernes à analyser automatiquement des images dermoscopiques ou cliniques afin d'identifier des motifs visuels complexes, parfois difficilement perceptibles à l'œil humain. L'essor du Deep learning, et plus particulièrement des réseaux de neurones convolutifs, a considérablement amélioré les performances de ces systèmes, en permettant l'extraction automatique de caractéristiques discriminantes à partir des images [12], [13].

Dans ce contexte, ce chapitre présente d'abord les concepts fondamentaux de l'intelligence artificielle, de la machine learning et du Deep learning, avant d'aborder plus spécifiquement la classification des images de la peau, ses caractéristiques, ses principaux types, ainsi que la problématique scientifique liée au diagnostic automatisé des lésions cutanées [13].

II.2. Intelligence Artificielle (IA)

II.2.1. Définition

L'intelligence artificielle désigne un ensemble de méthodes, de modèles et de systèmes informatiques conçus pour accomplir des tâches nécessitant habituellement l'intelligence humaine, telles que la reconnaissance de formes, la prise de décision, l'apprentissage à partir de données ou encore la résolution de problèmes complexes. Dans le domaine biomédical, l'IA permet de traiter de grandes quantités de données hétérogènes, notamment des images, afin d'assister les professionnels de santé dans le diagnostic, la prédiction et le suivi thérapeutique [12].

L'intelligence artificielle (IA) regroupe des techniques permettant aux machines de reproduire certaines capacités humaines. Parmi ses principaux sous-domaines, la machine learning permet aux systèmes d'apprendre à partir de données sans programmation explicite, tandis que le Deep learning constitue une branche avancée basée sur des réseaux de neurones profonds capables d'extraire automatiquement des caractéristiques complexes, notamment dans les images médicales [12], [14].




Figure II.1 – Le schéma général de l'IA

II.2.2. Machine Learning (Apprentissage automatique)

II.2.2.1. Définition

La machine learning est une discipline de l'intelligence artificielle qui vise à développer des modèles capables d'apprendre automatiquement des relations, des structures ou des régularités à partir de données. Au lieu de s'appuyer sur des règles fixes, ces modèles construisent une fonction de décision à partir d'exemples observés (voir figure II.2).

Dans le domaine de l'imagerie médicale, et plus particulièrement pour la classification des images de la peau, la machine learning joue un rôle essentiel. Il est utilisé pour analyser des images dermatologiques afin de distinguer différentes catégories de lésions, comme les lésions bénignes et malignes. Selon le type d'approche, les algorithmes peuvent exploiter des caractéristiques extraites des images de manière manuelle (comme la couleur, la texture ou la forme) ou automatiquement. Ces informations permettent ensuite aux modèles de réaliser des tâches de classification, de détection d'anomalies ou de prédiction de pathologies cutanées, contribuant ainsi à l'aide au diagnostic médical [13], [14].




Figure II.2 – Les catégories d'apprentissage automatique.

II.2.2.2. Apprentissage supervisé

L'apprentissage supervisé repose sur l'utilisation d'un ensemble de données annotées, dans lequel chaque exemple d'entrée est associé à une sortie connue. L'objectif du modèle est d'apprendre une fonction de correspondance entre les entrées et les étiquettes, afin de pouvoir prédire correctement la classe de nouvelles données jamais vues. Dans le cas des lésions cutanées, une image peut être associée à une étiquette. Cette étiquette peut par exemple indiquer la lésion est « bénigne ». Elle peut aussi indiquer qu'elle est « maligne ». Elle peut également indiquer qu'il s'agit d'un « mélanome ». Ou encore d'un « nævus ». Ou enfin d'une « kératose » [13].

En classification médicale, Ce modèle est le plus utilisé, car les tâches diagnostiques nécessitent généralement des labels fiables fournis par des experts. Toutefois, il dépend fortement de la disponibilité de données annotées de qualité, ce qui constitue souvent une contrainte majeure dans le domaine médical [14].

II.2.2.3. Apprentissage non supervisé

L'apprentissage non supervisé consiste à analyser des données non étiquetées afin d'y découvrir des structures cachées, des regroupements ou des régularités intrinsèques. Dans ce cadre, le modèle ne dispose pas de classes prédéfinies, mais cherche à organiser les données selon leur similarité. En imagerie dermatologique, cette approche peut être utile pour explorer des sous-types de lésions, réduire la dimensionnalité des données ou préparer des représentations utiles avant une tâche supervisée [14]. Même s'il est moins utilisé directement pour le diagnostic final, l'apprentissage non supervisé conserve un intérêt important dans les situations où les annotations sont rares, coûteuses ou incomplètes, ce qui est fréquent dans les bases médicales réelles [15].

II.2.2.4. Apprentissage par renforcement

L'apprentissage par renforcement repose sur l'interaction entre un agent et un environnement. L'agent apprend à sélectionner des actions en maximisant une récompense cumulative. Contrairement à l'apprentissage supervisé, il ne s'appuie pas sur des étiquettes fixes mais sur un mécanisme d'essais et d'erreurs [12]. Dans le domaine de la classification d'images cutanées, cette approche est moins répandue que les méthodes supervisées ou profondes. Néanmoins, elle peut être envisagée dans certains scénarios spécifiques, par

exemple pour optimiser des stratégies de décision séquentielle, des protocoles d'exploration clinique ou des systèmes interactifs d'aide au diagnostic [14].

II.2.3. Deep Learning (Apprentissage profond)

Le Deep learning est une branche de la machine learning fondée sur des réseaux de neurones artificiels composés de plusieurs couches successives. Sa particularité essentielle réside dans sa capacité à apprendre automatiquement des représentations hiérarchiques des données : les premières couches capturent des motifs simples, tandis que les couches profondes construisent des représentations de plus en plus abstraites et sémantiques. Cette propriété a révolutionné la vision par ordinateur et l'analyse d'images médicales [12], [13].

Dans le cas des images cutanées, le Deep learning permet d'éviter, dans une large mesure, la dépendance à l'extraction manuelle de caractéristiques. Les modèles apprennent directement à partir des pixels de l'image, ce qui améliore leur robustesse et leur capacité à modéliser la variabilité des lésions. Cette évolution explique la prédominance actuelle des architectures profondes dans les systèmes de classification dermatologique assistée par ordinateur [13], [16].




Figure II.3 - Architecture globale d'apprentissage profond.

II.2.3.1. Convolutional Neural Networks (CNN)

Les réseaux de neurones convolutifs (CNN) constituent aujourd'hui les architectures les plus employées dans le domaine de l'analyse d'images. Ils tirent parti de l'organisation spatiale des images en utilisant des filtres locaux capables d'identifier automatiquement différents types de motifs, comme les contours, les textures, les formes ou encore des structures plus élaborées (comme illustré dans la figure II.4). Grâce au partage des poids ainsi qu'à la localité des connexions, ces réseaux diminuent considérablement le nombre de

paramètres à entraîner comparativement aux réseaux de neurones entièrement connectés classiques [12].

Dans le domaine du diagnostic dermatologique, les réseaux de neurones convolutifs (CNN) ont démontré une grande efficacité pour la classification des lésions observées en dermoscopie. Ils sont capables d'apprendre automatiquement des caractéristiques visuelles discriminantes liées notamment à la couleur, à la symétrie, à la texture ou encore aux structures vasculaires, ce qui leur a permis d'obtenir des performances remarquables sur plusieurs bases de données de référence [17], [18].




Figure II.4 - Architecture général d'un CNN.

II.2.3.1.1. Typologie des architectures des réseaux de neurones convolutifs

Les architectures de réseaux de neurones convolutifs (CNN) se divisent en plusieurs familles selon leur structure et leurs mécanismes d'apprentissage. Les modèles séquentiels classiques reposent sur un empilement linéaire de couches de convolution, d'activation et de Pooling afin d'extraire progressivement des caractéristiques visuelles des images.

Des architectures plus avancées ont ensuite été développées pour améliorer les performances et faciliter l'entraînement des réseaux profonds. VGG augmente la profondeur du réseau grâce à l'utilisation répétée de petits filtres convolutifs, tandis que ResNet introduit des connexions résiduelles permettant de limiter le problème de disparition du gradient. DenseNet favorise la réutilisation des caractéristiques entre les couches, alors qu'Inception exploite plusieurs tailles de filtres pour capturer des informations à différentes échelles. Enfin,

EfficientNet optimise simultanément la profondeur, la largeur et la résolution afin d'obtenir un bon compromis entre précision et coût computationnel [12], [14].

Dans la classification des lésions cutanées, ces architectures sont souvent utilisées via l'apprentissage par transfert ou adaptées sous forme de modèles personnalisés. Le choix du modèle dépend principalement de la taille du jeu de données, des ressources matérielles disponibles, de la complexité des lésions et des exigences de généralisation clinique [14].

II.2.3.1.2. Architecture des réseaux de neurones convolutifs

L'architecture d'un CNN repose sur une succession de couches ayant chacune une fonction spécifique dans le processus d'apprentissage (comme représenté dans la figure II.5). Ensemble, ces couches permettent de transformer progressivement l'image brute en une représentation numérique discriminante, adaptée à la tâche de classification [12].




Figure II.5 - Les couches de traitement d'un CNN.

II.2.3.1.2.1. Couche d'entrée (Input Layer)

La couche d'entrée reçoit l'image sous forme matricielle. Chaque image est généralement représentée par ses dimensions spatiales, c'est-à-dire la hauteur et la largeur, ainsi que par son nombre de canaux, souvent trois pour les images RGB. Avant d'entrer dans le réseau, l'image peut subir des opérations de redimensionnement, de normalisation ou d'augmentation des données [13].

II.2.3.1.2.2. Couche de convolution

La couche de convolution applique des filtres ou noyaux qui parcourent l'image afin d'extraire des caractéristiques locales. Chaque filtre produit une carte d'activation mettant en évidence la présence d'un motif particulier (comme montré sur la figure II.6). Les premières couches détectent généralement des structures simples comme les contours ou les contrastes, tandis que les couches plus profondes capturent des formes plus complexes et plus abstraites [12].




Figure II.6 - Couche de convolution.

II.2.3.1.2.3. Couche de sous-échantillonnage (Pooling Layer)

La couche de Pooling réduit la dimension spatiale des cartes de caractéristiques tout en conservant l'information la plus pertinente. Cette réduction diminue la complexité du modèle, améliore l'efficacité computationnelle et introduit une certaine invariance aux petites translations ou déformations (comme observable sur la figure II.7). Le Max-Pooling est l'une des formes les plus utilisées dans les architectures CNN classiques [12].




Figure II.7 – Exemple d'une opération de Max Pooling de taille 2 x 2.

II.2.3.1.2.4. Fonction d'activation

La fonction d'activation apporte de la non-linéarité au sein du réseau, ce qui lui permet d'apprendre des relations complexes entre les entrées et les sorties [12]. Parmi les fonctions les plus couramment utilisées, on retrouve notamment ReLU, qui facilite l'apprentissage en accélérant la convergence et en réduisant les problèmes de saturation des gradients (comme illustré à la figure II.8).




Figure II.8 – Exemple d'une fonction d'activation ReLU.

II.2.3.1.2.5. Couche d'aplatissement (Flatten Layer)

La couche d'aplatissement transforme les cartes de caractéristiques multidimensionnelles issues des couches de convolution en un vecteur unidimensionnel (tel que montré dans la figure II.9). Cette étape permet de relier les blocs convolutifs aux couches de classification finale. Bien qu'elle soit classique dans de nombreuses architectures, certaines approches modernes lui substituent des opérations de global Average Pooling afin de limiter le nombre de paramètres [13].




Figure II.9 – Exemple d'une couche d'aplatissement.

II.2.3.1.2.6. Couche entièrement connectée (Fully Connected Layer)

Les couches entièrement connectées combinent les caractéristiques extraites précédemment afin de produire une décision de classification (comme observable sur la figure II.10). Elles jouent un rôle similaire à celui d'un classificateur final et permettent d'intégrer globalement l'information issue des différentes cartes de caractéristiques apprises par le réseau [12].




Figure II.10 - Couche entièrement connectée.

II.2.3.1.2.7. Couche de sortie

La couche de sortie fournit la prédiction finale du réseau. Dans un problème binaire, elle peut comporter un seul neurone avec une activation sigmoïde ; dans un problème multiclassés, elle comporte autant de neurones que de classes, généralement avec une activation Softmax produisant des probabilités de classe [12].

II.2.3.1.2.8. Techniques d'optimisation et de régularisation des CNN

L'entraînement efficace d'un CNN dépend non seulement de son architecture, mais aussi des méthodes utilisées pour optimiser l'apprentissage et améliorer la capacité de généralisation. Les techniques de régularisation visent à limiter le sur-ajustement, tandis que les techniques d'optimisation facilitent la convergence et la stabilité du processus d'apprentissage [12].

II.2.3.1.2.8.1. Fonction de perte

La fonction de perte mesure l'écart entre les prédictions du modèle et les étiquettes réelles. Elle guide l'algorithme d'apprentissage en indiquant dans quelle direction les paramètres doivent être ajustés. En classification multiclass, l'entropie croisée catégorielle est largement utilisée, car elle pénalise fortement les prédictions incorrectes et permet une optimisation efficace par rétropropagation [12].

II.2.3.1.2.8.2. Dropout

Le dropout est une technique de régularisation consistant à désactiver aléatoirement une partie des neurones pendant l'apprentissage (la figure II.11 met en évidence cet aspect). Cette stratégie empêche le réseau de s'appuyer excessivement sur certaines connexions spécifiques, réduit la coadaptation des neurones et améliore la généralisation sur des données nouvelles [17].




Figure II.11 – Exemple d'application du Dropout sur un réseau neural

II.2.3.1.2.8.3. Normalisation par lots (Batch Normalization)

La batch normalisation consiste à normaliser les activations au sein de mini-lots pendant l'entraînement. Cette technique stabilise la distribution des entrées internes, permet l'utilisation de taux d'apprentissage plus élevés, accélère l'entraînement et peut, dans certains cas, réduire le besoin d'autres formes de régularisation [18].

II.2.3.1.2.8.4. Arrêt anticipé (Early Stopping)

L'arrêt anticipé est une technique consistant à interrompre l'apprentissage lorsque la performance sur l'ensemble de validation commence à se dégrader, même si l'erreur sur l'ensemble d'entraînement continue à diminuer. Elle permet ainsi d'éviter que le modèle ne s'ajuste excessivement aux données d'apprentissage [17].

II.2.3.1.2.8.5. Augmentation des données

L'augmentation des données consiste à générer de nouvelles variantes d'images à partir des images originales, par des transformations géométriques ou photométriques telles que la rotation, la symétrie, le recadrage, le zoom ou les modifications de couleur. Cette stratégie augmente artificiellement la diversité des données et contribue à améliorer la robustesse du modèle, notamment lorsque les bases médicales sont limitées [19].

II.2.3.1.2.8.6. Optimiseurs d'apprentissage

Les optimiseurs d'apprentissage ajustent les poids du réseau à partir des gradients calculés pendant la rétropropagation. Parmi eux, Adam est l'un des plus utilisés, car il combine l'adaptation individuelle des taux d'apprentissage avec une bonne efficacité pratique, y compris dans les problèmes de grande dimension ou de gradients bruités [20].

II.2.3.2. Autres approches du Deep Learning

Les réseaux de neurones convolutifs (CNN) dominent largement le domaine de l'analyse d'images ; toutefois, d'autres approches d'apprentissage profond sont également employées en imagerie médicale. Les autoencodeurs sont notamment utilisés pour apprendre des représentations compactes des données ou pour réaliser des tâches de débruitage. Les réseaux antagonistes génératifs (GAN), quant à eux, sont particulièrement adaptés à la synthèse de nouvelles images et à l'augmentation des données. Plus récemment, les transformeurs visuels ainsi que les architectures hybrides associant CNN et Transformer connaissent un intérêt croissant grâce à leur capacité à modéliser les relations globales entre les différentes régions de l'image.

Dans le cas des lésions cutanées, ces approches peuvent être combinées aux CNN pour améliorer certaines étapes du pipeline, comme la segmentation, la génération de données synthétiques ou l'apprentissage de représentations plus robustes face à la variabilité inter-patient et inter-appareil [12], [16].

II.2.3.3. Apprentissage par transfert (Transfer Learning)

L'apprentissage par transfert repose sur la réutilisation des connaissances acquises par un modèle préalablement entraîné sur une base de données de grande taille, généralement composée d'images généralistes comme ImageNet. Plutôt que de concevoir un modèle

entièrement à partir de zéro, cette approche consiste à utiliser un réseau préentraînés comme base, puis à l'adapter à une tâche spécifique en ajustant certaines couches du modèle (tel qu'illustré dans la figure II.12 [18]). Les couches initiales, qui apprennent des caractéristiques visuelles générales telles que les contours, les textures et les formes, sont conservées, tandis que les couches finales sont réentraînées afin de répondre aux exigences de la tâche cible.

Cette méthode présente un intérêt majeur en imagerie médicale, où les données annotées sont souvent limitées en raison du coût élevé et du temps nécessaire à l'intervention des spécialistes. En exploitant des représentations visuelles déjà apprises, l'apprentissage par transfert permet de réduire la quantité de données requise pour l'entraînement tout en améliorant les capacités de généralisation des modèles. Il contribue également à accélérer le processus d'apprentissage, à diminuer les ressources computationnelles nécessaires et à limiter le risque de sur apprentissage [14].

Dans le cadre de la classification des lésions cutanées, l'apprentissage par transfert est largement utilisé pour adapter des modèles préentraînés à des bases de données spécialisées. Cette adaptation, souvent réalisée par une phase de fine-tuning, permet au modèle d'apprendre les caractéristiques spécifiques des lésions cutanées, notamment les variations de couleur, de texture et de structure. Les travaux récents montrent que cette stratégie améliore considérablement les performances de classification, notamment en termes de précision, de sensibilité et de spécificité, tout en réduisant les coûts computationnels liés à l'entraînement des modèles [13], [17].




Figure II.12 – Le principe de l'apprentissage par transfert (Transfer Learning).

II.2.3.4. Le sur-ajustement

Le sur-ajustement, ou overfitting, apparaît lorsqu'un modèle apprend trop fidèlement les particularités de l'ensemble d'entraînement, y compris le bruit ou les variations non généralisables. Il obtient alors de très bons résultats sur les données d'apprentissage, mais échoue à maintenir cette performance sur de nouvelles données. Ce phénomène est particulièrement critique en médecine, où un modèle doit être capable de généraliser à des images provenant d'autres centres, appareils, populations ou conditions cliniques [17].

Dans les tâches dermatologiques, le sur-ajustement peut être favorisé par la faible taille des bases de données, le déséquilibre entre classes, les biais de collecte ou encore la présence d'artefacts visuels tels que poils, reflets, règles de mesure ou marques de peau. Pour y remédier, plusieurs techniques sont couramment utilisées : dropout, batch Normalization, augmentation des données, Early Stopping, validation croisée et apprentissage par transfert [20], [21].

II.3. Classification des images de la peau

II.3.1. Définitions

La classification d'images de la peau est un processus automatique ou semi-automatique consistant à attribuer une image cutanée à une catégorie diagnostique déterminée. Dans le contexte médical, cette classification vise à distinguer différentes lésions, par exemple bénignes ou malignes, ou à reconnaître plusieurs classes cliniques comme le mélanome, le nævus mélanocytaires, la kératose bénigne, le carcinome bas cellulaire ou les lésions vasculaires [13], [16].

Cette tâche est d'une grande importance clinique, car elle peut contribuer à un dépistage plus rapide, à une réduction de la charge de travail des dermatologues et à une amélioration de la détection précoce des lésions graves. Toutefois, elle ne remplace pas l'expertise médicale ; elle constitue plutôt un système d'aide à la décision, dont la fiabilité dépend de la qualité des données et de la robustesse du modèle [14].

II.3.2. Les caractéristiques des images de la peau

Les images dermatologiques présentent des caractéristiques visuelles complexes et hétérogènes. L'interprétation correcte d'une lésion repose sur plusieurs indices, notamment la

texture, la couleur, la forme, la distribution des structures, les motifs vasculaires et l'aspect global de la surface cutanée. Les systèmes de classification automatique doivent donc être capables de modéliser cette diversité afin de différencier des lésions parfois très proches visuellement [13].

II.3.2.1. Texture

La texture décrit l'organisation locale des intensités et des motifs au sein de l'image. Dans les lésions cutanées, elle peut refléter une granulation, une homogénéité, une rugosité ou des structures internes spécifiques. La texture est une caractéristique importante, car certaines lésions bénignes et malignes se distinguent par des patrons texturaux différents [13].

II.3.2.2. Couleur

La couleur représente un des indices les plus significatifs en dermatologie. Les variations de teinte, de saturation et de distribution chromatique peuvent renseigner sur la nature de la lésion. Une hétérogénéité importante de couleur, la présence de teintes noires, bleutées, rouges ou blanchâtres, ainsi qu'une distribution irrégulière peuvent orienter vers une suspicion de malignité [13].

II.3.2.3. Lésions cutanées

Les lésions cutanées présentent une grande hétérogénéité : elles peuvent être pigmentées ou non, bénignes ou malignes, d'origine inflammatoires ou tumorales. Cette diversité rend la tâche de classification automatique particulièrement complexe. C'est pourquoi les bases de données dermatologiques actuelles intègrent de multiples classes diagnostiques, dans le but de mieux refléter la variabilité observée en pratique clinique [15].

II.3.2.4. Vascularisation

La vascularisation est un élément dermoscopique important, surtout dans les lésions non pigmentées où elle peut fournir des informations déterminantes pour le diagnostic. La forme et la disposition des vaisseaux (arborisés, ponctués, glomérulaires ou linéaires irréguliers) aident à différencier les types de lésions et à orienter le diagnostic. L'analyse de ces structures, ainsi que leur organisation spatiale, joue donc un rôle clé dans l'évaluation dermatologique assistée par ordinateur, en particulier pour la distinction entre lésions bénignes et malignes [15].

II.3.2.5. Épaisseur

L'épaisseur de la lésion influence son relief, ses ombres, sa perception de profondeur et parfois son expression visuelle globale. Bien qu'elle soit plus difficile à estimer directement à partir d'une image 2D, elle peut être suggérée par certains indices morphologiques ou par des modalités d'imagerie complémentaires. Dans le cas du mélanome, l'épaisseur tumorale possède également une valeur pronostique clinique importante [13].

II.3.2.6. Hydratation

L'hydratation cutanée influence l'aspect optique de la peau, notamment son niveau de brillance, de sécheresse ou de desquamation. Même si ce paramètre n'est pas toujours mesuré explicitement dans les bases d'images dermatologiques, il peut affecter la qualité des acquisitions et la visibilité de certains détails diagnostiques [15].

II.3.2.7. Élasticité

L'élasticité est une propriété biomécanique de la peau liée à sa capacité à se déformer puis à retrouver son état initial. Dans l'analyse purement visuelle d'images standards, elle n'est généralement pas observée directement, mais peut être liée à certains aspects morphologiques ou à des données cliniques complémentaires. Son intérêt est donc plus marqué dans des approches multimodales que dans la seule classification image [15].

II.3.2.8. Texture de surface

La texture de surface renvoie à l'apparence externe de la lésion, par exemple lisse, kératosique, squameuse, croûteuse ou ulcérée. Elle complète l'analyse globale de la texture interne et constitue un indice important pour distinguer certaines classes lésionnelles. Les réseaux profonds peuvent apprendre ces indices de manière implicite lorsqu'ils sont entraînés sur des bases suffisamment représentatives [13].

II.3.3. Types de classification

Les systèmes de classification d'images cutanées peuvent être conçus selon différents schémas en fonction du nombre de classes et de la nature des étiquettes à prédire. Le choix du type de classification dépend du problème clinique posé, de la qualité des annotations disponibles et de l'objectif final du système d'aide au diagnostic.

II.3.3.1. Classification binaire

La classification binaire consiste à répartir les images en deux catégories seulement, par exemple « bénigne » et « maligne ». Ce type d'approche est particulièrement utile pour le dépistage initial, lorsqu'il s'agit d'identifier rapidement les cas suspects nécessitant une évaluation dermatologique approfondie [13].

II.3.3.2. Classification multiclassés

La classification multiclassés attribue chaque image à une seule classe parmi plusieurs catégories possibles. Dans les bases dermatologiques comme ISIC, ce type de classification est fréquent, avec des classes telles que mélanome, nævus, kératose bénigne, dermato fibrome, carcinome basocellulaire, lésion vasculaire ou kératose actinique [17].

II.3.3.3. Classification multi-label

La classification multi-label permet d'associer plusieurs étiquettes à une même image. Elle est utile lorsque l'image contient simultanément plusieurs attributs diagnostiques, morphologiques ou cliniques. Bien que moins fréquente que la classification multiclassés dans les études dermatologiques classiques, elle devient pertinente dans des cadres plus riches, intégrant à la fois le diagnostic, les structures dermoscopiques et des métadonnées cliniques [15].

II.3.4. Problématique

La classification automatique des lésions cutanées demeure une problématique particulièrement complexe en raison des nombreuses difficultés associées à l'analyse des images médicales. Les lésions bénignes et malignes présentent souvent des caractéristiques visuelles très proches, ce qui rend leur distinction difficile, même pour des dermatologues expérimentés. De plus, les images dermoscopiques peuvent être affectées par différentes sources de variabilité, telles que les conditions d'éclairage, la qualité des dispositifs d'acquisition, les différences de résolution ou encore la présence d'artefacts comme les poils, les ombres et les reflets. À ces contraintes s'ajoutent le déséquilibre des classes dans les bases de données médicales ainsi que la rareté des annotations expertes, facteurs qui compliquent davantage l'apprentissage des modèles de classification [15].

Dans ce contexte, le développement d'un système automatisé capable d'identifier les différentes lésions cutanées avec précision, robustesse et fiabilité constitue un défi majeur. Les méthodes traditionnelles montrent souvent leurs limites face à la diversité et à la complexité des données médicales. En revanche, les approches basées sur l'apprentissage profond offrent des perspectives prometteuses grâce à leur capacité à extraire automatiquement des caractéristiques pertinentes et discriminantes directement à partir des images. Par ailleurs, l'utilisation de techniques telles que l'apprentissage par transfert et les architectures profondes contribue à améliorer la capacité de généralisation des modèles tout en réduisant les effets du manque de données annotées et du sur-ajustement [13], [14].

C'est dans cette optique que s'inscrit notre projet de fin d'études, dont l'objectif est de concevoir un système intelligent fondé sur l'apprentissage profond afin de différencier automatiquement les lésions bénignes des lésions malignes de manière rapide, fiable et efficace. Cette approche vise à fournir un outil d'aide au diagnostic capable de soutenir les professionnels de santé dans la détection précoce du cancer de la peau et dans l'amélioration de la qualité de la prise en charge des patients.

II.4. Conclusion

Au cours de ce chapitre, nous avons présenté les notions fondamentales relatives à l'intelligence artificielle ainsi qu'aux différents paradigmes de l'apprentissage automatique, en mettant l'accent sur les réseaux de neurones. Nous avons ensuite approfondi l'apprentissage profond appliqué à l'analyse des images médicales, en détaillant les réseaux de neurones convolutifs (CNN), leurs architectures, ainsi que les techniques d'optimisation et de régularisation qui contribuent à améliorer leurs performances en classification d'images. Le chapitre a également couvert d'autres approches du Deep learning, l'apprentissage par transfert et la problématique du sur-ajustement, éléments essentiels pour renforcer la précision et la capacité de généralisation des modèles. Enfin, nous avons présenté les principales caractéristiques des images médicales utilisées dans ce travail et introduit le problème général de la classification d'images.

CHAPITRE III

MISE EN ŒUVRE DU SYSTEME DE CLASSIFICATION

Le diagnostic et l'analyse précoces du cancer de la peau sont déterminants. Ils permettent d'améliorer les taux de survie. Ils réduisent également les coûts liés aux traitements. Cependant, les problèmes liés à la détection et à la classification rapide de cette maladie varient grandement en fonction des ressources disponibles, des installations médicales et du degré de développement technologique des pays.

Dans les chapitres précédents, nous avons présenté les différentes techniques de traitement ainsi que les architectures des réseaux de neurones convolutifs (CNN), qui sont au cœur de nos travaux actuels. Nous allons maintenant présenter et interpréter les résultats obtenus à partir de la modélisation et de la classification des images cutanées. Cette démarche a pour objectif d'aider les médecins à mieux identifier les différences entre les lésions malignes et bénignes. Elle leur fournit un outil de diagnostic efficace pour prendre les bonnes décisions.

III.1. Introduction

Le cancer de la peau est une maladie caractérisée par une prolifération anormale de cellules dans les tissus cutanés. Normalement, les cellules de la peau se renouvellent de manière régulière : les cellules vieillissantes meurent et sont remplacées par de nouvelles cellules. Toutefois, lorsque ce mécanisme est perturbé, notamment à la suite d'une exposition aux rayons ultraviolets (UV), la croissance cellulaire peut devenir excessive et incontrôlée. Dans certains cas, ces cellules peuvent rester non cancéreuses (bénignes) sans ne se propager ni causer de dommages importants.

L'intelligence artificielle (IA), et plus particulièrement les réseaux de neurones convolutifs (CNN), s'impose aujourd'hui comme un outil performant pour l'analyse et la classification des images médicales. Ces approches permettent d'identifier les lésions cutanées à partir d'images de haute résolution, renforçant ainsi la capacité des professionnels de santé à poser un diagnostic du cancer de la peau de manière plus rapide et plus précise. Dans ce contexte, notre travail porte sur l'utilisation de deux architectures de réseaux de neurones convolutifs (CNN) : DenseNet169 et VGG19, pour la classification du cancer de la peau. Ces modèles ont été choisis pour leurs performances reconnues dans la classification d'images complexes et leur aptitude à extraire des caractéristiques discriminantes permettant de distinguer efficacement les lésions bénignes des lésions malignes.

L'objectif de ce travail est de concevoir et d'évaluer un système de classification automatique du cancer de la peau capable d'analyser des images dermatologiques et de fournir des diagnostics fiables. Ce processus comprend la préparation et le prétraitement des données, l'entraînement de modèles CNN ; ainsi que l'évaluation de leurs performances à travers les différentes métriques. Dans les sections suivantes, nous présenterons en détail les méthodes et les algorithmes utilisés, ainsi que les bases de données d'images cutanées employées, et nous analyserons les résultats obtenus. Cette étude a pour objectif de mettre en évidence le potentiel des techniques d'apprentissage profond pour améliorer les outils de diagnostic médical, mais aussi d'ouvrir des perspectives pour leur intégration dans la pratique clinique quotidienne.

III.2. Environnement de développement

La mise en œuvre d'une application dédiée au cancer de la peau repose sur une phase d'analyse préalable indispensable pour définir les besoins, les contraintes et les objectifs, et ainsi concevoir une solution adaptée. Dans le cadre de ce projet, l'objectif est de développer

un système de détection automatique du cancer cutané à partir d'images dermatologiques, en utilisant l'environnement Python et ses bibliothèques spécialisées dans le traitement d'images et l'intelligence artificielle.

III.2.1. Outil de développement : Python

III.2.1.1. Définition

Python est un langage de programmation de haut niveau largement utilisé dans les domaines de la science, de l'intelligence artificielle et de l'analyse de données. Il doit son succès dans le domaine de l'apprentissage automatique à sa syntaxe claire, sa grande lisibilité, la richesse de ses bibliothèques et sa capacité à accélérer le prototypage des solutions complexes. Dans le cadre de cette étude, Python a constitué l'outil principal pour programmation de l'ensemble de la chaîne de traitement, notamment pour le chargement des images, leur prétraitement, l'entraînement des modèles et l'évaluation des performances [18].

Le choix de ce langage est également justifié par la disponibilité de bibliothèques spécialisées telles que TensorFlow, Keras, NumPy, scikit-image, ainsi que d'autres outils dédiés au traitement d'images et à l'apprentissage profond. Ces bibliothèques permettent de mettre en œuvre des architectures avancées, d'exploiter le transfert d'apprentissage et de standardiser le développement expérimental. Grâce à cet environnement, la conception du système de classification devient plus flexible, plus robuste et mieux adaptée aux applications biomédicales qui requièrent précision et reproductibilité [22], [23].

III.2.2. Base de données

Dans cette étude, la base de données utilisée est issue de l'archive International Skin Imaging Collaboration (ISIC), une référence internationale largement exploitée dans le domaine de la classification automatique des lésions cutanées. Cette base regroupe des images dermoscopiques (RGB) recueillies auprès de différents centres cliniques internationaux de renom, obtenues à partir de divers dispositifs utilisés au sein de chaque centre. Nous avons utilisé l'ensemble de données de référence publique ISIC 2019, bien établi pour l'évaluation du modèle proposé [24]. Afin de garantir une évaluation fiable des performances du modèle, le dataset est divisé en deux sous-ensembles : un ensemble d'entraînement pour l'apprentissage et un ensemble de test pour la validation des résultats.

L'utilisation de la base ISIC est justifiée par la qualité des images fournies, la fiabilité des annotations médicales et la diversité clinique des lésions disponibles. Cette diversité permet

d'améliorer la capacité du modèle à distinguer plusieurs types de lésions cutanées dans un contexte de classification multiclasse [24].

III.3. Conception et implémentation d'un système de classification

III.3.1. Objectif

L'objectif de ce système est de développer une solution automatique capable de classer les images de peau selon leur catégorie diagnostique à partir d'images dermoscopiques. Une telle approche vise à aider le spécialiste à détecter précocement les anomalies cutanées en réduisant le temps d'analyse et en améliorant la cohérence du diagnostic. Il ne s'agit pas de remplacer l'expertise médicale, mais de proposer un outil d'aide à la décision basé sur des méthodes modernes d'apprentissage profond [16], [25].

Sur le plan méthodologique, l'objectif est également de comparer l'efficacité de deux architectures de réseaux de neurones convolutifs, DenseNet169 et VGG19, afin d'identifier celle qui s'adapte le mieux à la nature des données étudiées. Cette comparaison permet d'évaluer non seulement la précision de la classification, mais aussi la robustesse et la capacité de généralisation du système proposé.

III.3.2. Schéma général de conception

Le système conçu suit une chaîne de traitement structurée (cf. figure III.1). Dans un premier temps, les images sont collectées puis soumises à une phase de prétraitement visant à améliorer leur qualité visuelle et à réduire l'impact des éléments perturbateurs. Elles sont ensuite préparées en vue de l'apprentissage, à travers un redimensionnement, une normalisation et, et le cas échéant, le recours à une stratégie de transfert d'apprentissage. Enfin, les modèles CNN sélectionnés extraient automatiquement les caractéristiques discriminantes et produisent la décision de classification [22], [23].

III.3.2.1. Prétraitement des images

Le prétraitement des images représente une étape clé dans les systèmes de détection et de classification des images de la peau, puisqu'il permet d'optimiser la qualité des données en amont de leur exploitation par les modèles de Deep Learning.




Figure III.1 - Schéma général de conception de système de la classification.

III.3.2.1.1. Importance du prétraitement

Le prétraitement est une étape déterminante dans tout système d'analyse d'images médicales. Dans le cas des lésions cutanées, les images peuvent contenir des éléments

perturbateurs tels que des cheveux, des bulles d'air, des variations d'éclairage, des bords sombres ou du bruit numérique. Si ces éléments ne sont pas corrigés, ils peuvent détourner le modèle de classification des caractéristiques réellement pertinentes et entraîner une baisse des performances. Le prétraitement vise donc à rendre les images plus homogènes et plus informatives pour l'algorithme d'apprentissage [26].

Au-delà de l'amélioration visuelle, le prétraitement joue également un rôle dans la stabilité de l'apprentissage. Un ensemble d'images mieux standardisé permet au réseau de converger plus facilement et de réduire l'influence des variations non clinique. En ce sens, cette étape agit comme un filtre méthodologique essentiel entre les données brutes et le processus de classification [22].

III.3.2.1.2. Correction des artefacts

La correction des artefacts est une étape essentielle du prétraitement des images dermatologiques. Son principal objectif est de supprimer ou d'atténuer les éléments indésirables présents dans l'image qui pourraient perturber l'analyse automatique des lésions cutanées. Parmi ces artefacts figurent notamment les poils, les marques de repérage tracées par les cliniciens, les bulles d'air, les reflets lumineux, les ombres, ainsi que certaines irrégularités introduites lors de l'acquisition de l'image par le dispositif dermoscopique. Ces éléments parasites peuvent masquer partiellement la lésion, altérer ses contours ou modifier sa texture et sa couleur, ce qui risque d'entraîner des erreurs lors des étapes d'analyse ultérieures.

Afin de remédier à ces problèmes, différentes techniques de traitement d'image sont employées, telles que les filtres morphologiques, les méthodes d'interpolation, les algorithmes de détection et de suppression des poils, ainsi que les approches basées sur l'apprentissage automatique. La correction des artefacts permet ainsi d'améliorer la qualité visuelle de l'image, de rendre la région d'intérêt plus clairement visible et de préserver les informations pertinentes liées à la lésion. En conséquence, cette étape favorise une classification plus précise et facilite l'extraction des caractéristiques discriminantes utilisées pour la classification et le diagnostic assisté par ordinateur des lésions cutanées [26].

III.3.2.1.3. Normalisation des intensités

La normalisation des intensités permet d'homogénéiser les valeurs lumineuses et chromatiques des images afin de réduire les écarts provoqués par les conditions de capture.

Dans les bases de données dermoscopiques, il est fréquent que certaines images soient plus sombres, plus contrastées ou plus saturées que d'autres. Sans normalisation, ces différences peuvent être interprétées à tort comme des indices cliniques par le modèle [26].

Cette opération améliore la cohérence globale de la base de données et rend les images plus comparables entre elles. Elle permet ainsi au réseau de se concentrer davantage sur la morphologie, la couleur et la texture réelles des lésions plutôt que sur des variations liées à l'acquisition. Dans les systèmes basés sur le transfert d'apprentissage, cette standardisation est d'autant plus importante que les modèles préentraînés attendent généralement des entrées conformes à un format précis [22], [23].

III.3.2.1.4. Réduction du bruit

La réduction du bruit vise à atténuer les fluctuations indésirables présentes dans l'image, sans dégrader l'information utile fournie par la lésion. Dans le cas des images médicales, le bruit peut provenir du capteur, de la compression ou de conditions d'acquisition imparfaites. Son traitement est important, car il peut altérer les contours, les détails fins et la texture, qui sont souvent des éléments discriminants dans l'analyse dermatologique [26].

L'enjeu de cette étape est de trouver un équilibre entre le nettoyage et la conservation de l'information. Un filtrage excessif peut lisser des détails importants, tandis qu'un filtrage insuffisant laisse persister des perturbations susceptibles d'affecter la qualité des prédictions. C'est pourquoi la réduction du bruit doit être intégrée dans une stratégie globale de prétraitement, évaluée quantitativement et visuellement [26].

IV.3.2.1.5. Évaluation de l'efficacité du processus de prétraitement

L'évaluation de l'efficacité du prétraitement des images de la peau est une étape importante. Elle permet de mesurer la qualité des transformations appliquées aux images. Cette étape est essentielle avant d'exploiter les images par les modèles de Deep Learning. Elle permet également de vérifier l'impact des opérations de réduction du bruit, de normalisation et d'amélioration du contraste sur la qualité des données d'entrée. Pour cette évaluation, deux métriques quantitatives ont été utilisées : l'erreur quadratique moyenne, qui mesure l'écart entre l'image originale et l'image traitée, et le rapport signal sur bruit de crête, qui permet d'évaluer la qualité de l'image reconstruite ou prétraitée. Ces indicateurs fournissent une mesure objective de l'efficacité des techniques de prétraitement utilisées.

a) Erreur quadratique moyenne (Mean Square Error (MSE))

L'erreur quadratique moyenne (MSE) est une métrique utilisée pour quantifier la différence entre une image originale et son image prétraitée, c'est-à-dire une image modifiée pour corriger certains défauts. Elle correspond à la moyenne des carrés des écarts entre les valeurs des pixels des deux images, ce qui implique une comparaison de chaque pixel de l'image initiale avec celui de l'image transformée. Si la valeur de MSE est faible, alors les deux images sont très similaires. Cela indique qu'un prétraitement a bien été effectué et qu'il a été efficace. En revanche, si la valeur de MSE est élevée, alors les deux images sont très différentes. Cela indique qu'une dégradation plus marquée a eu lieu.

Pour deux images I et K de dimension $m \times n$, la MSE est définie par l'expression suivante :

$$MSE = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} (I(i,j) - K(i,j))^2 \quad \dots (III.1)$$

où $I(i,j)$ représente le pixel de l'image originale, $K(i,j)$ celui de l'image traitée, et m, n les dimensions de l'image.

b) Rapport crête signal sur bruit (Peak Signal to Noise Ratio (PSNR))

Le PSNR (Peak Signal-to-Noise Ratio), qui est une mesure dérivée du MSE, permet d'évaluer la qualité d'une image reconstruite par rapport à une image de référence. Il est exprimé en décibels (dB) et indique le rapport entre la puissance maximale du signal et la puissance du bruit introduit lors du traitement. Une valeur élevée du PSNR traduit une meilleure qualité d'image, c'est-à-dire une image plus nette et une distorsion plus faible, soit une image plus fidèle à la réalité.

Le PSNR est défini par la formule suivante :

$$PSNR = 10 \log_{10} \left(\frac{MAX_I^2}{MSE} \right) \quad \dots (III.2)$$

où MAX_I représente la valeur maximale des pixels de l'image (par exemple 255 pour une image en 8 bits).

Cette métrique permet d'évaluer la qualité des images après traitement. Elle permet également de vérifier que les opérations appliquées, telles que l'ajustement du contraste ou de la luminosité, n'ont pas altéré de manière significative les informations visuelles. En pratique, une très bonne qualité d'image est indiquée par un PSNR supérieur à 40 dB, une bonne qualité

par une valeur comprise entre 30 et 40 dB, une qualité moyenne par une valeur comprise entre 20 et 30 dB, et une faible qualité d'image est traduite par une valeur inférieure à 20 dB.

c) Résultats illustratifs

Les résultats du prétraitement peuvent également être évalués visuellement, en comparant les images avant et après traitement, ce qui permet de visualiser les changements opérés. Cette comparaison permet d'observer à la fois la réduction du bruit, l'amélioration du contraste et la clarification des contours. En pratique, les résultats sont souvent présentés sous forme de figures et de tableaux. Ces observations qualitatives, qui offrent une évaluation plus complète de la qualité du processus de prétraitement (voir le tableau III.1) et complètent les mesures quantitatives telles que le MSE et le PSNR.

Tableau III.1- Résultats MSE et PSNR après le prétraitement des images.

Image	MSE	PSNR (dB)
Image 1	1,54	46,26
Image 2	4,26	41,84
Image 3	2,98	43,38
Image 4	1,93	45,28
Image 5	5,51	40,72

Le tableau III.1 présente les valeurs de l'Erreur Quadratique Moyenne (MSE) et du Rapport Signal sur Bruit de Crête (PSNR) obtenues pour cinq images après l'étape de prétraitement. Les résultats montrent globalement des valeurs de MSE très faibles et des valeurs de PSNR élevées indiquant ainsi une bonne qualité des images traitées et une faible dégradation par rapport aux images d'origine (cf. figure III.2).

Les images 1 et 4 affichent les meilleures performances avec des valeurs de MSE de 1,54 et 1,93 respectivement, et des PSNR de 46,26 dB et 45,28 dB. Ces résultats traduisent une excellente conservation des informations visuelles après prétraitement. Les images 2, 3 et 5 présentent des valeurs de MSE légèrement plus élevées, comprises entre 2,98 et 5,51, avec des PSNR variant de 40,72 dB à 43,38 dB. Bien que ces performances soient inférieures

à celles de l'image 1 et 4, les valeurs de PSNR restent largement supérieures à 40 dB, ce qui correspond généralement à une très bonne qualité d'image et à une faible présence d'erreurs perceptibles.




Figure III.2 - Résultat de prétraitement des images de la peau: (a) image originale, (b) image après le prétraitement.

Dans l'ensemble, ces résultats confirment l'efficacité des techniques de prétraitement appliquées. La faible erreur MSE observée et les valeurs élevées de PSNR montrent que les opérations réalisées ont permis d'améliorer la qualité des images tout en préservant leurs caractéristiques essentielles, favorisant ainsi une meilleure performance des modèles de classification basés sur le Deep Learning.

III.3.2.2. Détection et classification des images de peaux

III.3.2.2.1. Les architectures DenseNet169 et VGG19 : Modèles CNN

Les réseaux de neurones convolutifs (CNN) constituent aujourd'hui l'une des approches les plus performantes pour la classification d'images, ce qui en fait des outils très utiles en imagerie médicale. Leur principal avantage réside dans leur capacité à apprendre automatiquement des représentations hiérarchiques à partir de données brutes, sans nécessiter d'extraction manuelle des caractéristiques, ce qui représente un gain de temps considérable. Dans le cadre de cette étude, deux architectures de référence ont été retenues : DenseNet169 et VGG19. La comparaison de ces deux architectures permet d'évaluer l'influence de la profondeur, de la connectivité interne et de la réutilisation des caractéristiques sur la qualité de la classification. Elle permet également de déterminer comment ces éléments interagissent pour améliorer ou affecter ce résultat.

Dans le cadre de la classification des lésions cutanées, par exemple, ces architectures sont fréquemment mises en œuvre grâce au transfert d'apprentissage. Ce principe repose sur la réutilisation des poids initialement appris à partir d'une large collection d'images, avant d'affiner soigneusement le modèle pour une tâche plus spécifique. Cette méthode est particulièrement adaptée lorsque le volume de données médicales est limitée, car elle permet d'améliorer la convergence plus rapide et exploite des représentations visuelles déjà robustes, comme l'ont montré de nombreux travaux dans la littérature [23].

III.3.2.2.1.1. Le modèle DenseNet169

DenseNet169 est un réseau densément connecté (cf. Figure III.3). Son principe fondamental est le suivant : chaque couche reçoit en entrée les cartes de caractéristiques produites par l'ensemble des couches précédentes. Cette connectivité dense favorise la propagation de l'information, réduit le problème de la disparition du gradient et encourage la réutilisation des caractéristiques déjà apprises. Le modèle parvient ainsi à être à la fois

profond, efficace et relativement économe en paramètres, ce qui en fait un outil particulièrement performant. Dans le cadre de cette étude, DenseNet169 s'avère particulièrement intéressant pour l'analyse des images dermatologiques. Il permet en effet de préserver avec finesse des informations issues des premières couches tout en construisant progressivement des représentations plus abstraites. Cette propriété est utile pour détecter des variations subtiles de texture, de forme ou de couleur qui peuvent être décisives pour distinguer différentes lésions cutanées [18], [24].




Figure III.3 – Architecture d'un modèle DenseNet169.

- **Image d'entrée (Input Image) – $224 \times 224 \times 3$** : L'image dermatologique est introduite dans le réseau sous la forme d'une image couleur de dimensions 224×224 pixels. Les trois canaux correspondent aux composantes RVB (Rouge, Vert et Bleu), qui contiennent les informations visuelles nécessaires à l'analyse des lésions cutanées.
- **Couche de Convolution Initiale – $112 \times 112 \times 64$** : Cette première couche applique 64 filtres de convolution afin d'extraire les caractéristiques visuelles de bas niveau telles que les contours, les bords et les textures simples. Elle constitue la première étape de l'apprentissage des informations pertinentes présentes dans l'image.
- **Couche de Max Pooling – $56 \times 56 \times 64$** : La couche de Max Pooling réduit les dimensions spatiales des cartes de caractéristiques tout en conservant les informations les plus importantes. Cette opération permet de diminuer le coût computationnel et de limiter le risque de sur apprentissage.


- **Premier Dense Block (Dense Block 1) – 56×56** : Le premier bloc dense est composé de six couches densément connectées. Chaque couche reçoit les sorties de toutes les couches précédentes, favorisant ainsi la réutilisation des caractéristiques apprises et une meilleure propagation du gradient à travers le réseau.
- **Première Couche de Transition (Transition Layer 1) – $56 \times 56 \rightarrow 28 \times 28$** : Cette couche regroupe une normalisation par lot (Batch Normalization), une fonction d'activation ReLU, une convolution 1×1 et une opération d'Average Pooling. Son rôle est de réduire progressivement les dimensions des cartes de caractéristiques ainsi que le nombre de paramètres du modèle.
- **Deuxième Dense Block (Dense Block 2) – $28 \times 28 \times 128$** : Ce bloc contient douze couches densément connectées. Il permet l'apprentissage de caractéristiques plus élaborées telles que les textures complexes, les formes des lésions et les irrégularités présentes à la surface de la peau.
- **Deuxième Couche de Transition (Transition Layer 2) – $28 \times 28 \rightarrow 14 \times 14$** : La deuxième couche de transition poursuit la réduction des dimensions spatiales tout en préservant les informations importantes extraites par les couches précédentes.
- **Troisième Dense Block (Dense Block 3) – $14 \times 14 \times 256$** : Composé de trente-deux couches densément connectées, ce bloc extrait des caractéristiques de haut niveau telles que les asymétries, les contours irréguliers et les structures complexes des lésions cutanées.
- **Troisième Couche de Transition (Transition Layer 3) – $14 \times 14 \rightarrow 7 \times 7$** : Cette couche prépare les données pour le dernier bloc dense en réduisant davantage les dimensions des cartes de caractéristiques tout en conservant les informations les plus pertinentes.
- **Quatrième Dense Block (Dense Block 4) – $7 \times 7 \times 640$** : Le dernier bloc dense contient également trente-deux couches densément connectées. Il apprend les représentations les plus discriminantes et les plus pertinentes pour la tâche de classification finale.
- **Bloc Bottleneck** : Chaque couche interne de DenseNet est constituée d'une convolution 1×1 suivie d'une convolution 3×3 . La convolution 1×1 réduit le nombre de canaux afin de diminuer le coût de calcul, tandis que la convolution 3×3 extrait les caractéristiques importantes. Les sorties sont ensuite concaténées avec celles des couches précédentes afin de favoriser la circulation de l'information dans tout le réseau.
- **Couche Global Average Pooling (GAP) – $7 \times 7 \times 640 \rightarrow 1 \times 1 \times 640$** : La couche Global Average Pooling calcule la moyenne de chaque carte de caractéristiques pour produire un

vecteur compact de représentation. Cette approche réduit fortement le nombre de paramètres, remplace l'opération Flatten et contribue à diminuer le surapprentissage.

- **Couche Dropout :** La couche Dropout désactive aléatoirement 50 % des neurones lors de l'entraînement. Cette technique améliore la capacité de généralisation du modèle et réduit le risque d'overfitting.
- **Couche Entièrement Connectée (Fully Connected Layer) :** La couche entièrement connectée reçoit les caractéristiques extraites par DenseNet et établit les relations entre ces caractéristiques et les différentes classes à prédire.
- **Couche de Sortie Softmax :** La couche Softmax produit une distribution de probabilités sur les deux classes de cancer de la peau. Elle permet de déterminer la classe la plus probable parmi les deux. (Bénin et Malin). Cette étape marque la fin du processus de classification.

III.3.2.2.1.2. Le modèle VGG19

Le modèle VGG-19 est un réseau de neurones convolutifs profonds (Deep Convolutional neural network) composé de 19 couches dont 16 convolutionnelles et 3 entièrement connectées. Sa structure simple et répétitive facilite sa compréhension et sa mise en œuvre. Les principaux composants de cette architecture sont présentés dans la figure III.4 :



III.4 – Architecture d'un modèle VGG19.

- **Couches convolutionnelles (Convolutional Layers) :** Utilisation de filtres de taille 3×3 avec un pas (Stride) de 1 et un Padding de 1, permettant de préserver les dimensions spatiales des cartes de caractéristiques.

- **Fonction d'activation ReLU (Rectified Linear Unit) :** Appliquée après chaque couche convolutionnelles afin d'introduire de la non-linéarité et d'améliorer la capacité d'apprentissage du réseau.
- **Couches de Pooling (Pooling Layers) :** Utilisation du Max Pooling avec une fenêtre de 2×2 et un Stride de 2 pour réduire progressivement les dimensions spatiales tout en conservant les caractéristiques les plus importantes.
- **Couches entièrement connectées (Fully Connected Layers) :** Trois couches entièrement connectées sont placées à la fin du réseau afin d'effectuer la classification finale à partir des caractéristiques extraites.
- **Couche Softmax :** Dernière couche du réseau, utilisée pour calculer les probabilités d'appartenance de l'image aux différentes classes de sortie.

Dans cette étude, VGG19 est utilisé comme modèle de comparaison afin d'évaluer si une architecture plus classique peut rivaliser avec DenseNet169 sur une tâche de classification dermatologique, et ce, en analysant les performances de ces deux modèles sur des images dermatologiques. Son intérêt réside dans sa stabilité, sa simplicité conceptuelle et sa capacité à apprendre des descripteurs visuels pertinents, à condition que les images soient correctement préparées et normalisées [23] [27].

III.3.2.2.2. Les métriques d'évaluation de la classification

L'évaluation d'un système de classification ne saurait se limiter à une seule mesure. Dans le cas des bases de données médicales, il est essentiel d'utiliser plusieurs indicateurs afin d'apprécier les performances sous différents angles. En effet, un modèle peut afficher une bonne exactitude globale tout en étant peu efficace pour la détection d'une classe minoritaire ou cliniquement sensible. C'est pourquoi les métriques de robustesse, d'exactitude, de sensibilité, de spécificité, de précision et de FPR sont mobilisées dans cette étude.

III.3.2.2.2.1. Évaluation de la robustesse

La robustesse d'un modèle correspond à sa capacité à maintenir des performances satisfaisantes en présence de variations des données d'entrée, telles que des changements d'éclairage, de petites perturbations visuelles ou des différences de distribution entre les ensembles d'apprentissage et de test. Dans le domaine médical, cette qualité est essentielle, car les images réelles peuvent différer de celles utilisées pour l'entraînement.

III.3.2.2.2. Évaluation de la précision globale (Accuracy)

L'Accuracy représente la proportion de prédictions correctement réalisées par le modèle. Elle offre une vue d'ensemble du comportement du classificateur et constitue un premier indicateur de performance utile. Toutefois, dans un contexte de déséquilibre des classes, cette métrique peut s'avérer insuffisante, car un modèle peut obtenir une précision élevée tout en échouant à détecter correctement certaines catégories moins représentées.

La formule de l'Accuracy est la suivante :

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad \dots \text{ (III.3)}$$

où :

- TP: True Positives (vrais positifs)
- TN: True Negatives (vrais négatifs)
- FP: False Positives (faux positifs)
- FN: False Negatives (faux négatifs)

III.3.2.2.3. Sensibilité (ou Recall)

La sensibilité, également appelée « Recall » ou « taux de vrais positifs (VP) », correspond à la capacité du modèle à identifier correctement les cas positifs. Dans le domaine médical, cette métrique est cruciale, car elle reflète la probabilité de détecter effectivement une lésion appartenant à une classe donnée. Une faible sensibilité signifie que le système laisse échapper un grand nombre de cas positifs, ce qui peut poser problème dans un contexte diagnostique.

La formule du Recall est donnée par :

$$\text{Recall} = \frac{\text{TP}}{(\text{TP} + \text{FN})} \quad \dots \text{ (III.4)}$$

où :

- TP: nombre de vrais positifs (True Positives),
- FN: nombre de faux négatifs (False Négatives).

III.3.2.2.4. Spécificité

La spécificité traduit la capacité du modèle à reconnaître correctement les cas négatifs. Autrement dit, elle évalue le pourcentage d'éléments sains ou non concernés qui ne sont pas classés à tort comme positifs. Dans les systèmes d'aide au diagnostic, une bonne spécificité

permet de réduire les fausses alertes. Elle permet également d'éviter des examens complémentaires inutiles [28].

La formule de la spécificité est la suivante :

$$\text{Specificity} = \frac{\text{TN}}{\text{TN} + \text{FP}} \quad \dots \text{ (III.5)}$$

où :

- TN: vrais négatifs (True Négatives),
- FP: faux positifs (False Positives).

III.3.2.2.5. Précision

La précision correspond à la proportion de prédictions positives correctes. Elle apporte donc la réponse à la question suivante : parmi l'ensemble des cas déclarés positifs par le modèle, combien le sont effectivement ? Cette métrique est importante lorsque le coût des faux positifs est élevé ou lorsque l'on cherche à garantir la fiabilité des alertes produites par le système [28].

La formule de la précision est donnée par :

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad \dots \text{ (III.6)}$$

où :

- TP: nombre de vrais positifs (True Positives),
- FP: nombre de faux positifs (False Positives).

Une valeur élevée de la précision signifie que la plupart des lésions cutanées détectées comme cancéreuses sont effectivement des cancers de la peau.

III.3.2.2.6. False Positive Rate (FPR)

Le taux de faux positifs, ou FPR, exprime la proportion de cas négatifs classés à tort comme positifs. Il complète utilement la spécificité, dont il constitue en quelque sorte le pendant. Lors de l'évaluation d'un système médical, un FPR élevé signifie que le modèle génère trop d'alarmes incorrectes sont générées par le modèle, ce qui peut diminuer sa pertinence pratique malgré une bonne sensibilité [28].

La formule est :

$$\text{FPR} = \frac{\text{FP}}{\text{FP} + \text{TN}} \quad \dots \text{ (III.7)}$$

où

- FP: nombre de faux positifs (False Positives),
- TN: vrais négatifs (True Négatives).

III.4. Résultats expérimentaux

Nous avons étudié différentes méthodes de classification basées sur l'apprentissage profond. Ces procédés ont été appliqués à un ensemble d'images de peau réelle dans le but d'identifier et de classer différentes lésions cutanées.

Les images analysées sont en couleur (RVB) et présentent la même résolution. Par exemple, une image a une résolution de 640×480 pixels, ce qui signifie qu'elle est composée de 640 pixels en largeur et de 480 pixels en hauteur. Sa résolution horizontale et verticale est de 96 ppp, une valeur couramment utilisée pour l'affichage sur écran. La profondeur de couleur de 24 bits indique que chaque pixel est codé à l'aide de trois composantes de couleur (rouge, vert et bleu), permettant de représenter environ 16,7 millions de couleurs. Cette caractéristique est importante pour reproduire fidèlement les différentes teintes de la peau, telles que les variations de pigmentation, les rougeurs ou certaines lésions. Ces caractéristiques garantissent une qualité d'image suffisante pour les étapes de prétraitement, d'extraction de caractéristiques et d'analyse automatique dans les systèmes de diagnostic assisté par ordinateur des lésions cutanées.

III.4.1. Présentation des résultats

Les exemples traités sont des images de la peau en couleur de tailles identique. Cette série d'expérimentations porte sur des images dermatologiques réelles, classées en deux catégories : « bénin » et « malin ». L'objectif est de permettre la classification automatique des images de la peau afin d'identifier les lésions bénignes et de les distinguer des lésions malignes. Cela permettra d'améliorer le diagnostic précoce et d'orienter plus efficacement la prise en charge médicale des patients.

L'objectif de ces exemples est d'obtenir :

- Une analyse détaillée des résultats expérimentaux obtenus dans le cadre de la tâche de classification. Cette analyse s'appuie sur deux modèles de Deep Learning : DenseNet169 et VGG19. Cette analyse prendra en compte l'impact de deux techniques de prétraitement appliquées aux images : l'amélioration du contraste et la détection des artefacts. Son but est d'évaluer leur contribution aux performances des modèles.

- Identifier le modèle le plus performant : Cette étape consiste à comparer les performances des différentes architectures de Deep Learning utilisées, notamment DenseNet169 et VGG19, à l'aide de plusieurs métriques d'évaluation telles que l'exactitude (Accuracy), la précision (Precision), le rappel (Recall) et Spécificité. L'objectif est de déterminer le modèle offrant le meilleur compromis entre capacité de généralisation, robustesse et efficacité de classification.
- L'ambition de cette analyse est d'apprécier l'impact de la strate de transition employée entre l'extracteur de caractéristiques et les strates de classification. Pour ce faire, nous étudierons l'impact des couches Flatten et Global Average Pooling (GAP), ainsi que de leurs différentes architectures. La couche Flatten convertit les cartes de caractéristiques en un vecteur unidimensionnel, augmentant ainsi considérablement le nombre de paramètres entraînaables. En revanche, la couche Global Average Pooling (GAP) réduit chaque carte de caractéristiques à une seule valeur représentative, ce qui limite la complexité du modèle. L'étude comparera les performances, la capacité de généralisation, le risque de sur apprentissage et le coût computationnel de ces deux approches, tout en analysant leur comportement au sein des architectures DenseNet169 et VGG19.
- Trois scénarios ont été considérés. Ils servent à évaluer les performances du classifieur.
 - 1^{er} cas : constitution de la base d'apprentissage avec 90 % des images sélectionnées aléatoirement, tandis que la base de test représente les 10 % restantes.
 - Dans le deuxième cas, on sélectionne aléatoirement 80 % des images pour constituer la base d'apprentissage, et on utilise les 20 % restantes pour la base de test.
 - Dans le troisième cas, la base d'apprentissage est constituée de 70 % des images sélectionnées au hasard, tandis que la base de test représente les 30 % restants.

III.4.2. Analyse et discussion

Les résultats expérimentaux obtenus à l'aide des modèles DenseNet169 et VGG19 sont présentés de manière comparative. Cette comparaison met en évidence les différences entre les deux méthodes. Les performances de chaque modèle sont détaillées en termes de précision, ce qui permet de les comparer et de choisir celui qui correspond le mieux à ses besoins.

L'efficacité des techniques de prétraitement appliquées est mise en exergue par les résultats obtenus dans l'ensemble des images traitées (cf. Tableau III-1). Ces résultats montrent notamment que le contraste est amélioré et que les artefacts sont détectés. Ils

permettent également d'évaluer l'impact de ces techniques sur les performances des modèles. Les faibles valeurs de l'erreur quadratique moyenne (MSE) et les valeurs élevées du rapport signal sur bruit de crête (PSNR) indiquent que les opérations effectuées ont permis d'améliorer la qualité des images tout en préservant leurs caractéristiques essentielles. Cette amélioration permet une meilleure extraction des caractéristiques pertinentes, ce qui accroît de manière significative les performances des modèles de classification basés sur l'apprentissage profond.

Le tableau III.2 présente une comparaison des performances de deux architectures DenseNet169 et VGG19, en utilisant deux types de couches finales : Flatten et Global Average Pooling (GAP). Les résultats montrent que DenseNet169 obtient les meilleures performances globales, quelle que soit la couche utilisée. En particulier, les modèles DenseNet169 avec Flatten et GAP atteignent tous deux une précision de test de 98,11 %, soit un résultat supérieur aux performances de VGG19, qui obtient respectivement 96,23 % avec Flatten et 94,34 % avec GAP. De même, les valeurs de précision (Precision) et de sensibilité sont plus élevées pour DenseNet169 (98,17% et 98,11%) que pour VGG19.

Concernant la perte de test (Test Loss), le modèle DenseNet169 avec GAP présente la valeur la plus faible (0,1061), indiquant une meilleure capacité de généralisation et une plus grande confiance dans les prédictions malgré une précision identique à celle de DenseNet169 avec Flatten. Cette observation suggère que l'utilisation de GAP améliore la robustesse du modèle tout en réduisant considérablement sa complexité.

L'analyse du nombre de paramètres montre également un avantage important de GAP. Pour DenseNet169, le passage de Flatten à GAP réduit le nombre de paramètres de 33,5 millions à 13,1 millions, soit une diminution d'environ 61 %, tout en conservant exactement les mêmes performances de classification. Une tendance similaire est observée avec VGG19, où le nombre de paramètres passe de 26,5 millions à 20,2 millions. Cette réduction permet de diminuer la taille mémoire du modèle et le risque de sur apprentissage.

Concernant les mesures de diagnostic, DenseNet169 affiche une sensibilité de 98,11 %, ce qui signifie que la plupart des images positives ont été correctement détectées. Sa spécificité de 95,24 % témoigne également d'une excellente capacité à reconnaître les cas négatifs. Les modèles VGG19 présentent une sensibilité légèrement plus faible (96,23 % avec Flatten et 94,34 % avec GAP), mais leur spécificité reste identique à celle de DenseNet169.

Dans l'ensemble, ces résultats démontrent que DenseNet169 est plus performant que VGG19 pour la classification des images de peau. Parmi les variantes testées, DenseNet169

avec GAP apparaît comme le meilleur compromis entre performance et efficacité, car il maintient une précision très élevée (98,11 %), une sensibilité très dominante (98,11%), une spécificité élevée (95,24 %) et le nombre de paramètres le plus faible ainsi que la perte de test la plus faible. Ces caractéristiques en font le modèle le plus adapté pour une application pratique de classification automatique des images dermatologiques.

Tableau III.2 – Comparaison des performances des modèles DenseNet169 et VGG19 utilisant les couches Flatten et Global Average Pooling (GAP).

Model	DenseNet169		VGG 19	
layer	Flatten	GAP	Flatten	GAP
Total params	33. 549. 506 (127.98 MB)	13. 102. 274 (49.98 MB)	26. 480. 322 (101.01 MB)	20. 188. 866 (77.01 MB)
Test Accuracy	98 ,11%	98,11%	96,23%	94,34%
Test Loss	0,4359	0.1061	0.3363	0.2478
Precision	98,17 %	98, 17 %	96,23 %	94,45 %
Sensibilité	98,11 %	98,11 %	96,23 %	94,34 %
Spécificité	95,24 %	95,24 %	95,24 %	95,24 %

Pour évaluer les performances des modèles DenseNet169 et VGG19, nous avons effectué plusieurs expérimentations en modifiant la taille de l'ensemble de test. Cette dernière a été modifiée à 10 %, 20 % et 30 %. Les résultats présentés dans le tableau III.3 montrent que DenseNet169 surpasse globalement VGG19 pour toutes les configurations évaluées. En effet, DenseNet169 obtient des précisions de 96,30 %, 98,11 % et 97,50 % respectivement pour des tailles de test de 10 %, 20 % et 30 %, tandis que VGG19 atteint 92,59 %, 96,23 % et 92,50 %. La meilleure performance globale est observée avec DenseNet169 et une taille de test de 20 %, avec une précision de 98,11 %.

L'analyse de la fonction de perte (Test Loss) confirme cette tendance. DenseNet169 présente systématiquement des pertes plus faibles que VGG19, avec une valeur minimale de 0,0639 pour une taille de test de 30 %, ce qui indique une meilleure généralisation du modèle. À l'inverse, VGG19 affiche des pertes plus élevées, notamment 0,4926 lorsque 10 % des données sont utilisées pour le test.

Les métriques de précision (Precision) et de sensibilité suivent la même évolution. DenseNet169 obtient des valeurs comprises entre 96,60% et 98,17% pour la précision et entre 96,30% et 98,11% pour la sensibilité. VGG19, quant à lui, varie entre 92,50% et 96,23%. Ces résultats montrent que DenseNet169 est plus fiable pour l'identification correcte des différentes classes.

Concernant les performances diagnostiques, la sensibilité atteint 96,23 % pour VGG19 avec un test size de 20 % et 98,11 % pour DenseNet169 avec un test size de 20 %. Cela signifie que la plupart des cas positifs ont été correctement détectés dans ces configurations. Toutefois, DenseNet169 maintient des valeurs de sensibilité élevées, même lorsque la taille du test augmente, avec 97,50 % de sensibilité pour un test size de 30 %. En ce qui concerne la spécificité, DenseNet169 obtient sa meilleure valeur (100 %) avec une taille d'échantillon de 10 %, indiquant qu'aucun cas négatif n'a été mal classé. Les autres configurations conservent également des spécificités élevées, comprises entre 95,24 % et 96,77 %.

Un autre aspect important est la complexité des modèles. DenseNet169 nécessite seulement 13,1 millions de paramètres (49,98 MB) contre 20,2 millions de paramètres (77,01 MB) pour VGG19. Malgré cette architecture plus légère, DenseNet169 offre des performances supérieures sur l'ensemble des métriques étudiées, démontrant une meilleure efficacité dans l'extraction et la représentation des caractéristiques des images de peau.

En conclusion, les résultats indiquent que DenseNet169 est le modèle le plus performant et le plus efficace pour la classification des images dermatologiques. La configuration avec 20 % de données de test semble être le meilleur compromis, offrant une précision maximale (98,11 %), une sensibilité parfaite (100 %) et une spécificité élevée (95,24 %), tout en conservant une complexité relativement faible. Cette configuration semble donc la plus adaptée pour une utilisation pratique et fiable dans un système d'aide au diagnostic dermatologique.

Le tableau III.4 illustre les performances des modèles VGG19 et DenseNet169 en matière de classification. Ces deux modèles utilisent la couche Global Average Pooling (GAP) et une taille de test de 20 %. Ils se distinguent toutefois par leurs résultats, avec des variations notables en termes de précision et de complexité.

En effet, DenseNet169 atteint une précision de test de 98,11 %, contre 96,23 % pour VGG19, ce qui témoigne d'une capacité de classification des images de peau plus élevée. Cette supériorité est également observée au niveau de la précision (Precision) et du rappel

(sensibilité), qui atteignent respectivement 98,20 % et 98,11 % pour DenseNet169, contre 96,23 % pour ces deux métriques dans le cas de VGG19. Ces résultats indiquent que DenseNet169 identifie plus correctement les échantillons appartenant à chaque classe.

Tableau III.3 – Performances des modèles VGG19 et DenseNet169 (couche GAP) pour différentes tailles de l'ensemble de test.

Model	VGG 19			DenseNet169		
Test size	10 %	20 %	30 %	10 %	20 %	30 %
Total params	20. 188. 866 - (77.01 MB)			13. 102. 274 - (49.98 MB)		
Test Accuracy	92,59 %	96,23 %	92,50 %	96,30 %	98,11 %	97,50 %
Test Loss	0.4926	0.1551	0.2262	0.1407	0.1346	0.0639
Precision	93,42 %	96,23 %	92, 50 %	96,60 %	98,17 %	97,50 %
Sensibilité	92,59 %	96, 23 %	92, 50 %	96,30 %	98,11 %	97,50 %
Spécificité	81,82 %	95, 24 %	90, 32 %	100,00 %	95,24 %	96,77 %

L'analyse de la fonction de perte (Test Loss) confirme également cette tendance. DenseNet169 présente une perte de 0,0957, nettement inférieure à celle de VGG19 (0,2489). Une perte plus faible signifie que les prédictions du modèle sont plus proches des valeurs réelles et que sa capacité de généralisation est meilleure.

Concernant les performances diagnostiques, les deux modèles affichent une sensibilité élevée de 96,23 % pour VGG19 et de 98,11 % pour DenseNet169, ce qui prouve qu'ils détectent efficacement les cas positifs. Cependant, DenseNet169 se distingue par une spécificité de 100 %, contre 95,24 % pour VGG19. Cela signifie que DenseNet169 ne produit aucun faux positif sur l'ensemble de test, ce qui représente un avantage important dans un contexte de diagnostic médical où la réduction des erreurs de classification est essentielle.

Enfin, malgré ses meilleures performances, DenseNet169 est également plus compact, avec seulement plus de 13,1 millions de paramètres (49,98 MB) contre 20,2 millions de paramètres (77,01 MB) pour VGG19. Cette réduction d'environ 35 % du nombre de paramètres permet de diminuer les besoins en mémoire et en calcul tout en améliorant les résultats.

En conclusion, les résultats démontrent que l'association de DenseNet169 à une couche GAP constitue le modèle le plus performant pour la classification des images dermatologiques. Il offre en effet une meilleure précision, une perte plus faible, une spécificité parfaite et une architecture plus légère que VGG19, ce qui en fait le choix le plus approprié pour une application d'aide au diagnostic basée sur l'intelligence artificielle.

Tableau III.4 - Performances des modèles VGG19 et DenseNet169.

Model	VGG19	DenseNet169
layer	GAP	GAP
Test size	20	20
Total params	20. 188.866 - (77.01 MB)	13. 102.274 - (49.98 MB)
Test Accuracy	96,23 %	98,11%
Test Loss	0.2489	0.0957
Precision	96,23 %	98,20 %
Sensibilité	96,23 %	98,11 %
Spécificité	95,24 %	100,00 %

Ces résultats sont représentés sur les figures ci-dessous : La figure III.5 illustre l'évolution de la perte (loss) et de la précision (accuracy) pour les ensembles d'entraînement et de validation au cours des époques d'apprentissage du modèle. L'analyse de ces courbes permet d'évaluer la convergence et la capacité de généralisation du modèle.

La courbe de gauche montre que la perte d'entraînement (Training Loss) diminue rapidement, passant d'environ 0,58 lors de la première époque à une valeur proche de 0 à partir de la vingtième époque. Cette diminution continue indique que le modèle apprend efficacement les caractéristiques présentes dans les données d'entraînement. De son côté, la perte de validation (Validation Loss) diminue également fortement au début de l'apprentissage, passant d'environ 0,38 à moins de 0,10, puis se stabilise autour de cette valeur avec de légères fluctuations. L'écart observé entre les pertes d'entraînement et de validation à partir de la dixième époque suggère l'apparition d'un léger phénomène de surapprentissage (overfitting): le modèle continue d'améliorer ses performances sur les données d'entraînement sans gain significatif sur les données de validation. Toutefois, cet

écart reste modéré, ce qui indique que la capacité de généralisation du modèle demeure satisfaisante.

La courbe de droite représente l'évolution de l'accuracy. L'Accuracy d'entraînement augmente rapidement dès les premières époques pour atteindre presque 100 %, puis reste stable jusqu'à la fin de l'apprentissage. L'Accuracy de validation suit une tendance similaire, atteignant rapidement des valeurs élevées comprises entre 94 % et 98 %. Bien qu'elle présente quelques fluctuations au cours de l'entraînement, elle reste globalement stable et se stabilise à environ 98 %, confirmant ainsi les excellentes performances du modèle sur des données non vues pendant l'apprentissage.



Figure III.5 - Évolution de la perte Loss et de l'Accuracy de l'entraînement et de la validation du modèle DenseNet169.

Dans l'ensemble, ces courbes montrent que le modèle converge rapidement et atteint un niveau de performance élevé. La diminution simultanée des pertes et l'augmentation des précisions démontrent l'efficacité du processus d'apprentissage. Malgré un léger surapprentissage observé en fin d'entraînement, les résultats de validation restent très élevés, ce qui indique que le modèle possède une bonne capacité de généralisation et qu'il est bien adapté à la tâche de classification des images de peau. Ces observations sont cohérentes avec les résultats quantitatifs précédemment obtenus, notamment une précision de test supérieure à 98 % pour le modèle DenseNet169 avec couche GAP.




Figure III.6 - Évolution de la perte Loss et de l'Accuracy de l'entraînement et de la validation du modèle VGG19.

Cette figure (cf. figure III.6) illustre l'évolution de la perte (loss) et de la précision (accuracy) sur les ensembles d'entraînement et de validation au cours des 42 premières époques d'apprentissage. Les courbes permettent d'évaluer le comportement du modèle et sa capacité à généraliser sur des données qui n'ont pas été utilisées pendant l'entraînement.

La courbe de Training Loss montre une diminution progressive de la perte, passant d'environ 0,71 à 0,15 en fin d'apprentissage. Cette baisse régulière indique que le modèle apprend efficacement les caractéristiques présentes dans les données d'entraînement. En revanche, la couche de validation Loss diminue au début de l'apprentissage mais reste ensuite relativement instable, oscillant entre 0,25 et 0,48 avec plusieurs pics importants. Cette variabilité suggère que le modèle rencontre des difficultés pour maintenir des performances constantes sur les données de validation et qu'il est peut-être sensible aux variations des échantillons. L'écart croissant entre la perte d'entraînement et la perte de validation à partir de la vingtième époque constitue un signe de surapprentissage (overfitting); le modèle continue de s'adapter aux données d'entraînement sans amélioration proportionnelle sur les données de validation.

L'évolution de la précision globale d'entraînement (Training Accuracy) confirme cette observation. Celle-ci augmente rapidement, passant d'environ 54 % à plus de 93 %, puis se stabilise. La précision de validation (Validation Accuracy) suit une tendance générale à la hausse, atteignant des valeurs comprises entre 85 % et 96 %, Cependant, elle présente de

fortes fluctuations d'une époque à l'autre. Ces variations indiquent que les performances du modèle sur les données de validation sont moins stables que sur les données d'entraînement.

Malgré ces fluctuations, le modèle atteint une précision de validation élevée, proche de 95 %, ce qui montre qu'il conserve une bonne capacité de classification. Toutefois, la présence d'un écart notable entre les performances d'entraînement et de validation ainsi que les oscillations de la perte de validation suggèrent que le modèle pourrait bénéficier de techniques de régularisation supplémentaires, telles que l'early stopping, l'augmentation des données (data augmentation), l'ajout de dropout ou l'ajustement du taux d'apprentissage.

Dans l'ensemble, ces courbes indiquent que le modèle a bien appris les caractéristiques des images et atteint de bonnes performances, mais sa capacité de généralisation reste moins robuste que celle observée précédemment avec DenseNet169, où les courbes de validation étaient plus stables et la perte de validation plus faible. Ces résultats suggèrent que ce modèle est plus sensible au surapprentissage et présente une généralisation légèrement moins efficace.

IV.5. Conclusion

Dans ce chapitre, nous avons présenté les différentes expérimentations réalisées sur une base de données composée d'images dermoscopiques de lésions cutanées bénignes et malignes. Notre objectif principal était d'évaluer les performances des architectures de deep learning VGG19 et DenseNet169 pour la classification automatique des lésions cutanées.

Avant l'entraînement des modèles, plusieurs techniques de prétraitement ont été appliquées aux images. Celles-ci comprenaient notamment le redimensionnement des images, l'amélioration de la luminosité et du contraste, ainsi que l'évaluation de leur qualité à l'aide des indicateurs PSNR et MSE. Ces opérations ont permis d'améliorer la qualité des données d'entrée et de favoriser un apprentissage plus efficace des modèles.

Les résultats obtenus montrent que l'intégration de la couche Global Average Pooling (GAP) améliore significativement les performances des deux architectures. Cette approche permet de réduire le nombre de paramètres du réseau tout en limitant le risque de surapprentissage. Les modèles utilisant la couche GAP ont ainsi obtenu de meilleurs résultats en termes de précision, de rappel et de taux de classification correcte que ceux reposant sur la couche Flatten.

L'étude comparative a également révélé que DenseNet169 offre les meilleures performances en matière de classification des lésions cutanées. En revanche, VGG19, bien

qu'il fournisse des résultats satisfaisants, se caractérise par une architecture plus profonde et un nombre élevé de paramètres, ce qui entraîne une complexité computationnelle importante et des temps d'exécution plus longs. Cette étude met en évidence l'importance du prétraitement des images, du choix de l'architecture du réseau neuronal et de l'optimisation des paramètres pour la conception d'un système intelligent d'aide au diagnostic dermatologique basé sur l'apprentissage profond. Un tel système peut contribuer à la détection précoce des lésions malignes et à une meilleure distinction entre les lésions bénignes et malignes.

IV.1. Récapitulatif

Ce mémoire s'est articulé autour de différents volets. Ces volets portent sur le traitement des images médicales. Ils portent aussi sur l'exploitation des techniques d'intelligence artificielle. Ces techniques servent à la détection et la classification du cancer de la peau. Les principaux axes de recherche et de développement menés dans ce travail sont récapitulés ci-dessous, chacun d'entre eux étant détaillé dans la suite de cette section.

- Dans le cadre de cette étude, nous nous sommes intéressés au traitement des images médicales. À cet effet :
 - i) Nous avons analysé les caractéristiques et les particularités des images. Ces images sont issues de l'imagerie médicale. Nous avons mis en évidence l'importance de leur qualité et de leur précision. Cela permet de garantir un diagnostic fiable et pertinent.
 - ii) Nous avons également étudié les différentes techniques de traitement des images médicales, notamment les méthodes d'acquisition, de prétraitement et de classification, afin de pouvoir les appliquer dans notre travail. Ces approches sont essentielles pour améliorer la qualité des images et optimiser leur analyse, ce qui permet une meilleure interprétation clinique.
- Les progrès récents de l'intelligence artificielle, notamment de l'apprentissage profond, ont favorisé son utilisation dans le domaine médical, ce qui a permis, par exemple, de développer des outils d'imagerie médicale de pointe ou de créer des systèmes d'aide à la décision médicale. Les réseaux de neurones convolutifs (CNN) se distinguent par leur capacité à extraire automatiquement des caractéristiques pertinentes des images médicales, ce qui en fait des outils efficaces 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 de ce mémoire a été consacrée à une étude de l'état de l'art. Cette étude porte sur le cancer de la peau. Elle porte aussi sur les différentes techniques de

traitement numérique des images. Et sur les principaux modèles de classification des images médicales. Cette analyse a permis de mettre en évidence les avancées réalisées dans ce domaine, mais aussi de souligner l'efficacité des approches basées sur l'apprentissage automatique et l'apprentissage profond, qui ont démontré des performances prometteuses pour le diagnostic et la classification du cancer de la peau.

- La deuxième partie de ce travail a porté sur l'étude et l'application des réseaux de neurones convolutifs (CNN) à la classification des images médicales. Les expérimentations réalisées à l'aide de Python ont confirmé l'efficacité et la robustesse de ces modèles. Ils sont efficaces pour la classification des images de la peau. Ils sont même efficaces même avec des ensembles de données limités.
- La troisième et dernière partie de ce mémoire, qui a été consacrée à la mise en œuvre du modèle de réseau de neurones convolutifs étudié précédemment, a permis de conclure le travail de recherche. Nous avons procédé à son implémentation et à son évaluation sur une base d'images médicales de la peau afin d'analyser ses performances en matière de classification des lésions cutanées, et nous avons pu constater que cela nous a permis d'obtenir des résultats prometteurs. Les résultats obtenus ont mis en évidence l'efficacité et la robustesse du modèle DensNet169, qui a démontré une capacité remarquable à distinguer les lésions bénignes et des lésions malignes, ce qui en fait une avancée majeure dans le domaine de la médecine. Cette étude confirme ainsi la pertinence de l'utilisation des architectures CNN, et en particulier DensNet169, pour l'aide au diagnostic du cancer de la peau, ce qui ouvre la voie à de nouvelles possibilités pour la recherche médicale.

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

IV.2. Perspectives

Ce travail a ouvert plusieurs perspectives d'amélioration. Ces améliorations concernent l'imagerie médicale et l'intelligence artificielle. Il serait pertinent de comparer différentes architectures de réseaux de neurones profonds afin d'identifier les modèles les plus performants pour la classification des lésions cutanées et d'étendre le système à une classification multiclassées pour une analyse plus détaillée des cancers de la peau.

Le développement d'une application web ou mobile permettrait, d'une part, une utilisation en temps réel et, d'autre part, un accès facilité au dépistage. Par ailleurs, l'intégration de techniques d'intelligence artificielle explicable améliorerait l'interprétabilité des résultats et la confiance dans le modèle.

Enfin, la robustesse, la précision et la généralisation du système pourraient être renforcées par l'utilisation de données cliniques complémentaires ainsi qu'une validation sur des bases de données issues de plusieurs établissements hospitaliers.

BIBLIOGRAPHIE

- [1] World Health Organization (WHO). Ultraviolet radiation. <https://www.who.int/news-room/fact-sheets/detail/ultraviolet-radiation>
- [2] National Cancer Institute (NCI). Tool to Distinguish Moles from Melanoma. <https://www.cancer.gov/news-events/cancer-currents-blog/2016/moles-to-melanoma>.
- [3] Hanna JM et al. Emerging Minimally Invasive Technologies for the Detection of Skin Cancer. PMC. <https://pmc.ncbi.nlm.nih.gov/articles/PMC8538732/>
- [4] Stat Pearls/NCBI Bookshelf. Anatomy, Skin (Integument) <https://www.ncbi.nlm.nih.gov/books/NBK441980/>
- [5] DermNet. What is melanoma? An introduction. <https://dermnetnz.org/topics/what-is-melanoma-an-introduction>.
- [6] American Cancer Society. Melanoma Skin Cancer Risk Factors. <https://www.cancer.org/cancer/types/melanoma-skin-cancer/causes-risks-prevention/risk-factors.html>
- [7] American Cancer Society; Basal and Squamous Cell Skin Cancer Risk Factors. <https://www.cancer.org/cancer/types/basal-and-squamous-cell-skin-cancer/causes-risks-revention/risk-factors.html>
- [8] DermNet. Basal cell carcinoma. <https://dermnetnz.org/topics/basal-cell-carcinoma>.
- [9] DermNet NZ. Squamous cell carcinoma. <https://dermnetnz.org/cme/lesions/squamous-cell-carcinoma>.
- [10] DermNet NZ. Actinic keratosis. <https://dermnetnz.org/topics/actinic-keratosis>
- [11] NHS. Symptoms: Melanoma skin cancer. <https://www.nhs.uk/conditions/melanoma-skin-cancer/symptoms>.
- [12] LeCun Y., Bengio, Y., & Hinton, G. (2015). Deep Learning. *Nature*, 521, 436–444. <https://www.nature.com/articles/nature14539>.
- [13] Shetty B., Fernandes, R., Rodrigues, A. P., Chengoden, R., Bhattacharya, S., & Maddikunta, P. K. R. (2022). Skin lesion classification of dermoscopic images using machine learning and Convolutional neural network. *Scientific Reports*, 12. <https://www.nature.com/articles/s41598-022-22644-9>.

- [14] Kim, H. E., Cosa-Linan, A. Santhanam, N. Jannesari, M. Maros, M. E. & Ganslandt, T. (2022). Transfer learning for medical image classification: a literature review. BMC Medical Imaging, 22, 69. <https://link.springer.com/article/10.1186/s12880-022-00793-7>
- [15] Nugroho A. K., Wardoyo R., Wibowo M. E., et al. (2024). Image dermoscopy skin lesion classification using deep learning method: systematic literature review. <http://beei2.org/index.php/EEI/article/view/6077>
- [16] ISIC Archive / ISIC Challenge Datasets. <https://challenge.isic-archive.com/data/>
- [17] Srivastava N., Hinton G. Krizhevsky, A. Sutskever, I. & Salakhutdinov R. (2014). Dropout: A simple way to prevent neural networks from overfitting. Journal of Machine Learning Research, 15, 1929–1958. <https://jmlr.org/papers/v15/srivastava14a.html>
- [18] Python Software Foundation. The Python Language Reference. Documentation officielle Python. <https://docs.python.org/3/reference/introduction.html>
- [19] Shorten C. & Khoshgoftaar, T. M. (2019). A Survey on Image Data Augmentation for Deep Learning. Journal of Big Data, 6, 60. <https://link.springer.com/article/10.1186/s40537-019-0197-0>
- [20] Kingma D. P., & Ba, J. (2014). Adam: A Method for Stochastic Optimization. <https://arxiv.org/abs/1412.6980>
- [21] Prechelt L. (1997). Early Stopping – But When? https://page.mi.fu-berlin.de/prechelt/Biblio/stop_tricks1997.pdf
- [22] TensorFlow. Transfer learning & fine-tuning. Documentation officielle TensorFlow/Keras. https://www.tensorflow.org/guide/keras/transfer_learning.
- [23] TensorFlow. tf.keras. applications VGG19. Documentation officielle TensorFlow.: https://www.tensorflow.org/api_docs/python/tf/keras/applications/VGG19.
- [24] Noel C. F. Codella et al., “Skin Lesion Analysis Toward Melanoma Detection: A Challenge at the International Symposium on Biomedical Imaging (ISBI) 2016,” Proceedings of ISBI 2018, IEEE, 2018.
- [25] Classification: Accuracy, recall, precision, and related metrics. <https://developers.google.com/machine-learning/crash-course/classification/accuracy-precision-recall>

- [26] Joseph S., Olugbara O. (2022). Pre-processing Effects on Performance of Skin Lesion Saliency Segmentation. *Diagnostics*, 12(2), 344
- [27] Simonyan K., Zisserman A. (2015). Very Deep Convolutional Networks for Large-Scale Image Recognition. *ICLR 2015*.
- [28] Scikit-image developers. Skimage. Metrics documentation. Disponible sur : <https://scikit-image.org/docs/stable/api/skimage.metrics.html>