

الجمهورية الجزائرية الديمقراطية
الشعبية

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

وزارة التعليم العالي والبحث العلمي

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

جامعة أبي بكر بلقايد - تلمسان

Université Aboubakr Belkaïd – Tlemcen –

Faculté de TECHNOLOGIE



MEMOIRE

Présenté pour l'obtention du **diplôme** de **MASTER**

En : Génie Biomédical

Spécialité : Informatique Biomédicale et Hospitalière

Par : Hadj Mohammed Aissa & Djaziri Benyounes

Sujet

Classification et reconnaissance des maladies de la peau

Soutenu publiquement, le 13 /06 /2024 , devant le jury composé de :

BAAKEK Yettou Nour El Houda
BELAIDI Asma
BELAROUCI Sara

MCA
MAB
MAB

Université de Tlemcen
Université de Tlemcen
Université de Tlemcen

Présidente
Examinatrice
Encadrante

Année universitaire : 2023 /2024

Dédicace

À la mémoire de mon grand-père bien-aimé,

dont la sagesse et les souvenirs précieux continuent d'inspirer chacun de mes pas.

À mes chers parents,

*pour leur amour inconditionnel, leurs sacrifices et leur soutien indéfectible tout au long de
mon parcours.*

Votre foi en moi a été ma force et ma motivation pour réussir.

À tous les membres de ma famille,

pour leur affection, leur encouragement et leur soutien constants.

Vous avez été une source de réconfort et de joie dans ma vie.

À tous ceux qui m'ont soutenu depuis mon enfance jusqu'à l'obtention de ce diplôme,

vos aide et vos encouragements ont été inestimables et m'ont permis de réaliser ce rêve.

Merci du fond du cœur.

Aissa

Dédicace

Je dédie ce mémoire:

À la mémoire de mon petit frère Yacine, dont le souvenir restera toujours gravé dans mon cœur.

À mes chers parents, pour leur amour inconditionnel, leur soutien indéfectible et tous leurs sacrifices. Vous avez toujours été là pour moi, et je vous en suis infiniment reconnaissant.

À mes frères et à mes sœurs, pour leur affection, leur encouragement et leur présence constante dans ma vie.

À toute ma famille, pour son soutien et sa bienveillance.

À mes très chers amis, qui ont toujours été là pour moi, dans les bons comme dans les mauvais moments.

À toute personne qui m'a aidé d'un mot, d'une idée ou d'un encouragement, je dis "Merci" du fond du cœur. Votre soutien a été précieux pour moi, et je ne l'oublierai jamais.

Benyounes

Remerciements

Louange à Dieu, le Tout-Miséricordieux, le Très-Miséricordieux, qui nous a permis d'accomplir ce mémoire de fin d'études.

Nous tenons à exprimer notre profonde gratitude à Madame l'encadrante BELAROUCI Sara pour son encadrement précieux et ses conseils avisés tout au long de ce travail, de sa conception jusqu'à sa finalisation. Son dévouement et sa patience ont été d'un grand soutien pour nous.

Nos remerciements s'adressent également aux membres du jury de soutenance pour leur étude approfondie de notre mémoire et pour leurs suggestions constructives qui nous ont permis d'améliorer notre travail.

Nous tenons également à remercier l'ensemble du personnel enseignant et administratif de l'Université de Tlemcen pour leur accompagnement et leur soutien tout au long de notre parcours académique.

Enfin, nous adressons nos sincères remerciements à toutes les personnes qui, de près ou de loin, ont contribué à la réussite de ce mémoire.

Résumé

Ce projet de fin d'étude a exploré l'application de l'apprentissage profond pour la classification des maladies de la peau, en mettant un accent particulier sur les réseaux de neurones convolutifs (CNN). En utilisant les bases de données de référence ISIC et HAM10000, qui contiennent des images de diverses maladies cutanées, cette étude a évalué l'efficacité de différents modèles CNN. Plusieurs contributions ont été apportées pour améliorer les performances de classification, notamment grâce à des stratégies de prétraitement, d'équilibrage et d'optimisation.

Les résultats obtenus sont très prometteurs, atteignant des taux de classification de 92,8 % pour le modèle CNN classique et de 92 % pour DenseNet-121, et se comparent favorablement aux travaux existants dans la littérature. Ces résultats démontrent l'efficacité des architectures de réseaux neuronaux pour la classification des maladies de la peau.

Mots clés : *Apprentissage profond, réseaux de neurones convolutifs (CNN), classification des maladies de la peau, prétraitement, équilibrage, optimisation, performance, dermatologie.*

Abstract

This final project explores the application of deep learning, particularly convolutional neural networks (CNNs), for skin disease classification. Utilizing the benchmark ISIC and HAM10000 datasets, rich in images of diverse skin pathologies, this study evaluated the efficacy of different CNN models. Several contributions were made to enhance classification performance, including preprocessing, balancing, and optimization strategies.

The outcomes of our study are highly encouraging, with classification rates reaching 92.8% for the classic CNN model and 92% for DenseNet-121. These results are comparable to those of existing approaches in the literature and demonstrate the effectiveness of neural network architectures for skin disease classification.

Keywords: *Deep learning, convolutional neural networks (CNNs), skin disease classification, preprocessing, balancing, optimization, performance, dermatology.*

المخلص

هذا مشروع يستكشف تطبيق التعلم العميق، وتحديدًا شبكات الأعصاب التلافيفية (CNNs)، في تصنيف أمراض الجلد. باستخدام مجموعات البيانات المرجعية ISIC و HAM10000 الغنية بصور لأمراض جلدية متنوعة، قامت هذه الدراسة بتقييم فعالية نماذج CNN مختلفة. وقد تم تقديم العديد من المساهمات لتحسين أداء التصنيف، بما في ذلك استراتيجيات المعالجة المسبقة والموازنة والتحسين.

نتائج الدراسة مشجعة للغاية حيث وصلت معدلات التصنيف إلى 92.8% بالنسبة للنموذج الكلاسيكي لشبكات الأعصاب التلافيفية و 92% بالنسبة إلى DenseNet-121. النتائج التي تم الحصول عليها واعدة جدا وقابلة للمقارنة مع الاعمال المنجزة حاليا في هذا المجال. وتدل على فاعلية الشبكات الأعصاب التلافيفية لتصنيف الأمراض الجلدية.

الكلمات المفتاحية: التعلم العميق، شبكات الأعصاب التلافيفية (CNNs)، تصنيف أمراض الجلد، المعالجة المسبقة، الموازنة، التحسين، الأداء، الأمراض الجلدية.

Table des matières

<i>Dédicace</i>	i
<i>Dédicace</i>	ii
<i>Remerciements</i>	iii
<i>Résumé</i>	iv
<i>Abstract</i>	v
الملخص	vi
Table des matières.....	vii
Table des figures.....	iv
Liste des tableaux.....	iv
Liste d'abréviations.....	iv
Introduction Générale	1
Chapitre 1- Généralités sur les maladies de la peau	4
I. Introduction.....	5
II. Description de la peau.....	5
III. Analyse approfondie de l'anatomie de la peau.....	6
IV. Classification des maladies de la peau.....	7
IV.1. Classification selon l'étiologie.....	7
IV.2. Classification selon la présentation clinique.....	7
IV.3. Classification selon la sévérité.....	8
IV.4. Classification selon la localisation anatomique.....	8
V. Principales lésions élémentaires de la peau.....	9
V.1. Lésions primaires.....	9
V.1.1. Lésion visible mais non palpable.....	10
V.1.2. Lésions visibles et palpables.....	11
V.2. Lésions secondaires.....	11
VI. Les maladies de la peau.....	12
VI.1. Kératose actinique.....	12
VI.2. Carcinome basocellulaire.....	13
VI.3. Dermatofibrome.....	13
VI.4. Mélanome.....	13
VI.5. Nævus.....	14
VI.6. Kératose bénigne pigmentée.....	14
VI.7. Kératose séborrhéique.....	14

VI.8.	Carcinome épidermoïde.....	15
VI.9.	Lésion vasculaire.....	15
VI.10.	Kératoses actiniques et carcinome intraépithélial / Maladie de Bowen	16
VII.	Examens cliniques du diagnostic des maladies de la peau.....	16
VII.1.	Anamnèse et examen clinique.....	16
VII.2.	Examens complémentaires.....	16
VII.3.	Diagnostic final.....	17
VIII.	L'intelligence artificielle dans le diagnostic des maladies de la peau.....	17
VIII.1.	Analyse d'images et de données: vers un diagnostic plus précis et précoce.....	17
VIII.2.	Analyse des caractéristiques cliniques et aide au diagnostic différentiel.....	17
VIII.3.	Avantages de l'IA dans le diagnostic dermatologique.....	18
VIII.4.	Amélioration continue grâce à l'apprentissage automatique.....	18
IX.	Conclusion.....	18
	Chapitre 2 - Apprentissage profond pour la classification des maladies de la peau.....	19
I.	Introduction.....	20
II.	Apprentissage automatique.....	20
III.	Apprentissage profond.....	21
IV.	Réseaux de neurones convolutifs.....	22
IV.1.	Couches des réseaux neuronaux convolutifs.....	24
IV.1.1.	Couche de Convolution.....	24
IV.1.2.	Fonctions d'activation.....	25
IV.1.3.	Couche de pooling.....	26
IV.1.4.	Couche entièrement connectée.....	27
IV.1.5.	Couche de normalisation.....	28
IV.1.6.	Couche de Dropout.....	28
IV.1.7.	Fonction de perte.....	28
IV.1.8.	Algorithmes d'optimisation.....	28
IV.1.9.	Les Hyper-paramètres en Apprentissage Profond.....	29
IV.2.	Architectures de Classification les Plus Connues.....	30
IV.2.1.	Architecture VGG16.....	30
IV.2.2.	Architecture ResNet.....	31
IV.2.3.	Architecture DenseNet.....	33
IV.2.4.	Architecture MobileNet.....	34
V.	Avancées récentes dans la Classification des Affections Cutanées grâce à l'Apprentissage Profond	35
VI.	Conclusion.....	36

Chapitre 3 - Classification des maladies de la peau : Résultats et discussion	37
I. Introduction.....	38
II. Python.....	38
III. Outils d'implémentations	39
IV. Description des bases de données.....	39
1) Bases de données ISIC	40
2) Bases de Données HAM10000.....	41
V. Application d'un réseau de neurones convolutif classique pour la classification et la reconnaissance des maladies de la peau	43
VI. Utilisation d'algorithmes de transfert d'apprentissage pour la classification et la reconnaissance des maladies de la peau	44
VII. Critères d'évaluation.....	45
VIII. Contribution 1 : Stratégies de Prétraitement et d'Optimisation pour améliorer la Classification d'Images avec VGG16.....	46
1) Chargement de la base de données d'images ISIC	46
2) Répartition de la Base de Données.....	47
3) Application de VGG16.....	47
4) Réglage des Hyper-paramètres.....	48
5) Détection de l'Overfitting	48
6) Application de la Technique d'Augmentation	49
7) Ré-application de VGG16.....	50
IX. Contribution 2 : Analyse Comparative des performances de VGG16, ResNet50, DenseNet121 et MobileNet pour la Classification d'images.....	51
X. Contribution 3 : Analyse comparative entre les performances d'un modèle CNN classique et des modèles pré-entraînés.....	54
1) Chargement de la Base de Données HAM10000.....	54
2) Application de la technique de ré-échantillonnage.....	54
3) Analyse comparative entre les performances d'un modèle CNN classique et des modèles pré-entraînés	55
a. Réglage des Hyper-paramètres.....	55
b. Description du modèle CNN classique.....	56
c. Résultats et discussions	57
d. Évaluation des Prédications sur la Base de Test	61
XI. Comparaison de nos résultats avec l'état de l'art.....	62
XII. Conclusion.....	63
Conclusion Générale	64
Bibliographie	67

Table des figures

Figure 1.1 - Structure de la peau.....	5
Figure 1.2 - Analyse approfondie de l'anatomie de la peau.....	6
Figure 1.3 - Classification selon l'étiologie.....	7
Figure 1.4 - Classification selon la présentation clinique.....	8
Figure 1.5 - Classification selon la sévérité	8
Figure 1.6 - Classification selon la localisation anatomique.....	9
Figure 1.7 - Lésions primaires.....	9
Figure 1.8 - Lésions secondaires.....	12
Figure 1.9 - Kératose actinique.....	12
Figure 1.10 - Carcinome basocellulaire.....	13
Figure 1.11 - Dermatofibrome.....	13
Figure 1.12 - Mélanome.....	14
Figure 1.13 - Nævus.....	14
Figure 1.14 - Kératose bénigne pigmentée.....	14
Figure 1.15 - Kératose séborrhéique.....	15
Figure 1.16 - Carcinome épidermoïde	15
Figure 1.17 - Lésion vasculaire.....	15
Figure 1.18 - Maladie de Bowen.....	16
Figure 2.1 - Illustration de la relation entre l'intelligence artificielle, le machine Learning et le Deep Learning.	21
Figure 2.2 - Illustration d'un exemple de CNN pour la classification des images de maladies de la peau.	23
Figure 2.3 - Illustration d'un exemple d'opération de convolution appliquée à la reconnaissance d'images.....	25
Figure 2.4 - Le principe de fonctionnement du ReLU.	26
Figure 2.5 - Processus de max et average pooling avec fenêtre de taille 2x2 et pas 2.	27
Figure 2.6 - Couche entièrement connectée.....	27
Figure 2.7 - Architectures VGG16 et VGG19.....	31
Figure 2.8 - Architectures ResNet50.....	33

Figure 2.9 - L'architecture DenseNet-121, qui se compose de quatre couches de blocs denses et de trois couches de transition.	33
Figure 2.10 - Architectures MobileNet.....	35
Figure 3.1 - Répartition des classes dans la base de données ISIC.....	40
Figure 3.2 - Exemples d'images de la base de données ISIC.....	41
Figure 3.3 - Répartition des classes dans la base de données HAM10000.....	42
Figure 3.4 - Exemples d'images de la base de données HAM10000.....	42
Figure 3.5 - Répartition des classes dans la base de données ISIC.....	46
Figure 3.6 - Répartition de la Base de Données.....	47
Figure 3.7 – Résultats obtenus avant l'augmentation et l'équilibrage des données.....	48
Figure 3.8 - Répartition des classes dans la base de données après augmentation et équilibrage des données.....	49
Figure 3.9 – Résultats obtenus après l'augmentation et l'équilibrage des données.....	50
Figure 3.10 –Performance du modèle ResNet50 après augmentation et équilibrage des données.....	51
Figure 3.11 –Performance du modèle MobileNet après augmentation et équilibrage des données.....	52
Figure 3.12 –Performance du modèle DenseNet-121 après augmentation et équilibrage des données.....	52
Figure 3.13 –Performance du modèle VGG16 après augmentation et équilibrage des données.	53
Figure 3.14 - Répartition des classes dans la base de données HAM10000.....	54
Figure 3.15 –Performance du modèle CNN classique après l'équilibrage des données.....	57
Figure 3.16 – Matrice de confusion du modèle CNN classique.....	57
Figure 3.17 –Performance du modèle ResNet50 après l'équilibrage des données.....	58
Figure 3.18 – Matrice de confusion du modèle ResNet50.....	58
Figure 3.19 –Performance du modèle DenseNet-121 après l'équilibrage des données.....	59
Figure 3.20 – Matrice de confusion du modèle DenseNet-121.....	59
Figure 3.21 –Performance du modèle MobileNet après l'équilibrage des données.....	60
Figure 3.22 – Matrice de confusion du modèle MobileNet.....	60
Figure 3.23 –Performance du modèle VGG16 après équilibrage des données.....	61
Figure 3.24 – Matrice de confusion du modèle VGG16.....	61
Figure 3.25 – Résultats de prédiction pour la base de données ISIC.....	62
Figure 3.26 – Résultat de prédiction pour la base de données HAM10000.....	62

Liste des tableaux

Tableau 3.1- Description du Modèle CNN classique.....57

Tableau 3. 2- Taux de classification et F1-score obtenus62

Liste d'abréviations

1. **ADAM** : Adaptive Moment Estimation
2. **AI** : Artificial Intelligence (Intelligence Artificielle)
3. **AKIEC** : Actinic keratoses and intraepithelial carcinoma / Bowen's disease
4. **BCC**: basal cell carcinoma,
5. **BKL** : benign keratosis-like lesions (solar lentigines / seborrheic keratoses and lichen-planus like keratoses),
6. **BN** : Batch Normalization
7. **CNN** : Convolutional Neural Network (Réseau de Neurones Convolutifs)
8. **CSV** : Comma Separated Values
9. **DF** : dermatofibroma
10. **EM**: Erythema Migrans
11. **FC** : Fully connected
12. **GAN**: Generative Adversarial Network
13. **GD** : Gradient Descent
14. **HAM** : Human Against Machine (un défi ou une comparaison entre les performances humaines et les machines)
15. **ISIC** : International Skin Imaging Collaboration (Collaboration Internationale sur l'Imagerie de la Peau)
16. **LSTM**: Long Short-Term Memory
17. **MEL** : melanoma,
18. **ML** : Machine Learning (Apprentissage Automatique)
19. **MSE**: Mean Squared Error
20. **NV** : melanocytic nevi
21. **ReLU** : Rectified Linear Unit
22. **RN** : Réseau de Neurones
23. **RVB** : Red, Green, Blue
24. **ResNet** : Deep Residual Networks
25. **STGAN** : **Self-Transfer GAN**
26. **SGD** : Stochastic Gradient Descent
27. **SGDM** : SGD with Momentum
28. **VASC** : vascular lesions (angiomas, angiokeratomas, pyogenic granulomas and hemorrhage)
29. **VGG** : Visual Geometry Group

Introduction Générale

Contexte

Le diagnostic des maladies de la peau est un élément crucial de la dermatologie. Il exige souvent une expertise approfondie et une analyse minutieuse des images cliniques. Les maladies cutanées, allant des affections bénignes aux cancers de la peau potentiellement mortels, nécessitent une identification précise et rapide pour garantir un traitement efficace. Traditionnellement, ce processus dépendait largement de l'expertise des dermatologues, mais cette dépendance à l'interprétation humaine peut entraîner des erreurs et des retards. L'avènement de l'intelligence artificielle (IA) et des techniques d'apprentissage profond ouvre de nouvelles perspectives pour automatiser et améliorer la précision de ces diagnostics. Les réseaux de neurones convolutifs (CNN), une sous-catégorie de l'apprentissage profond, ont montré une efficacité remarquable dans la reconnaissance et la classification des images, ouvrant ainsi la voie à une transformation des pratiques cliniques en dermatologie.

Problématique

Malgré les progrès technologiques, plusieurs défis subsistent dans l'application de l'IA au diagnostic des maladies de la peau. L'un des principaux défis est le déséquilibre des données [1] : certaines classes de maladies de la peau sont surreprésentées, tandis que d'autres sont sous-représentées, ce qui peut biaiser les modèles et réduire leur efficacité. De plus, les modèles d'apprentissage profond nécessitent de grandes quantités de données annotées et un prétraitement minutieux pour atteindre des niveaux de précision clinique. Un autre problème crucial est le sur-apprentissage (overfitting), où le modèle apprend trop bien les détails et le bruit des données d'entraînement, au détriment de sa capacité à se généraliser à de nouvelles données. Ces défis soulèvent la question de savoir comment optimiser ces modèles pour qu'ils soient à la fois précis et généralisables à diverses conditions cliniques.

Motivation et objectifs

L'objectif principal de ce projet est d'explorer et d'évaluer l'efficacité des modèles d'apprentissage profond pour la classification des maladies de la peau, en mettant l'accent sur les CNN. Notre recherche vise à contribuer à la réduction des erreurs de diagnostic et à l'amélioration de la rapidité des décisions cliniques en fournissant aux dermatologues des outils automatisés et précis. En nous basant sur des ensembles de données de référence tels qu'ISIC [2] et HAM10000 [3], nous évaluons plusieurs architectures de CNN et analysons leurs performances en termes de précision, de robustesse et d'efficacité. Notre approche comprend également l'amélioration des modèles existants par le biais de techniques de

prétraitement, d'équilibrage des données et de comparaison entre les modèles classiques et pré-entraînés.

Contributions

Les principales contributions de ce projet sont les suivantes :

1. Mise en œuvre de stratégies de prétraitement et d'optimisation pour améliorer la classification des images avec l'architecture VGG16.
2. Analyse comparative des performances de VGG16, ResNet50, DenseNet121 et MobileNet pour la classification des images.
3. Comparaison des performances d'un modèle CNN classique et de modèles pré-entraînés pour la classification d'images équilibrées.

Organisation du mémoire

Notre mémoire est structuré en trois chapitres principaux, en plus de l'introduction générale et de la conclusion générale :

1. Chapitre 1 : Généralités sur les maladies de la peau

Ce chapitre présente un aperçu des maladies de la peau, y compris l'anatomie cutanée, la classification des pathologies cutanées, les aspects cliniques importants, les examens cliniques et le rôle prépondérant de l'intelligence artificielle.

2. Chapitre 2 : Apprentissage profond pour la classification des maladies de la peau

Ce chapitre explore les concepts fondamentaux de l'apprentissage automatique et se concentre sur les techniques d'apprentissage profond, en particulier les CNN. Il présente également les dernières avancées dans l'utilisation de l'apprentissage profond pour la classification automatique des affections cutanées.

3. Chapitre 3 : Classification des maladies de la peau : Résultats et discussion

Ce chapitre explore les défis du sur-apprentissage et du déséquilibre des données dans la classification des images médicales. Il présente des stratégies de prétraitement et d'optimisation pour améliorer la classification avec le modèle VGG16. Le chapitre compare également les performances de différents modèles CNN, notamment VGG16, ResNet50, DenseNet121 et MobileNet, et analyse les différences entre les modèles classiques et pré-entraînés. Enfin, il compare les résultats obtenus avec l'état de l'art dans le domaine.

Une conclusion générale qui synthétise toutes les idées extraites de nos différentes expérimentations et présente aussi les pistes de recherche ouvertes à partir de ce projet de fin d'étude.

Chapitre 1- Généralités sur les maladies de la peau

I. Introduction

Le diagnostic des maladies de la peau s'impose comme un domaine médical d'une grande complexité, nécessitant une maîtrise approfondie des diverses affections cutanées et des technologies de pointe permettant leur identification. Cette compréhension pointue est indispensable pour établir un diagnostic précis et efficace, pilier central du traitement et de la prise en charge des patients.

Dans ce chapitre, nous nous proposons d'explorer les multiples facettes du diagnostic dermatologique. Ensemble, nous parcourrons les spécificités cliniques des maladies de la peau, décrypterons l'anatomie cutanée dans ses moindres détails, analyserons la classification des différentes pathologies cutanées, définirons quelques maladies fréquentes, examinerons les examens cliniques essentiels au diagnostic, et enfin, nous nous pencherons sur le rôle prépondérant de l'intelligence artificielle dans le domaine médical et son impact révolutionnaire sur le diagnostic des maladies de la peau.

II. Description de la peau

La peau est un organe constituant l'enveloppe du corps. Son poids et sa surface varient en fonction de l'individu (âge, poids et taille) et atteignent environ 4 kg pour une surface de 2 m² chez un adulte moyen. Son épaisseur varie d'une personne à l'autre en fonction de l'âge, du sexe et de l'origine ethnique, mais également chez une même personne selon la localisation cutanée.

La peau est un organe complexe constitué de différentes couches qui sont (Voir la figure 1.1):

- L'épiderme (couche superficielle).
- Le derme (couche intermédiaire).
- L'hypoderme (couche profonde).

La peau possède de nombreux rôles importants, tels que : la protection, la barrière, la perception et la régulation thermique [4].

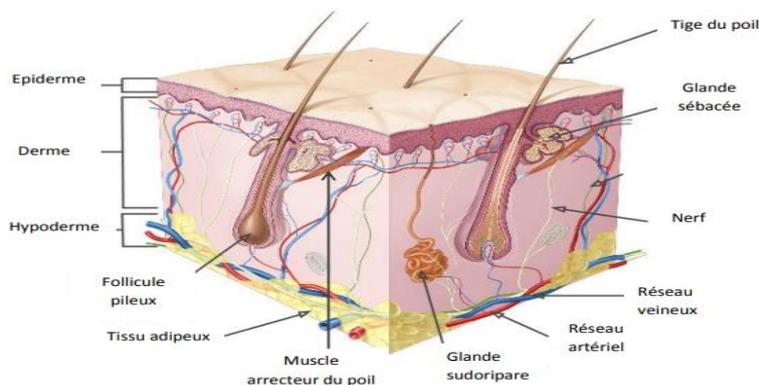


Figure 1.1 - Structure de la peau

III. Analyse approfondie de l'anatomie de la peau

La peau est composée de plusieurs couches distinctes remplissant des fonctions spécifiques :

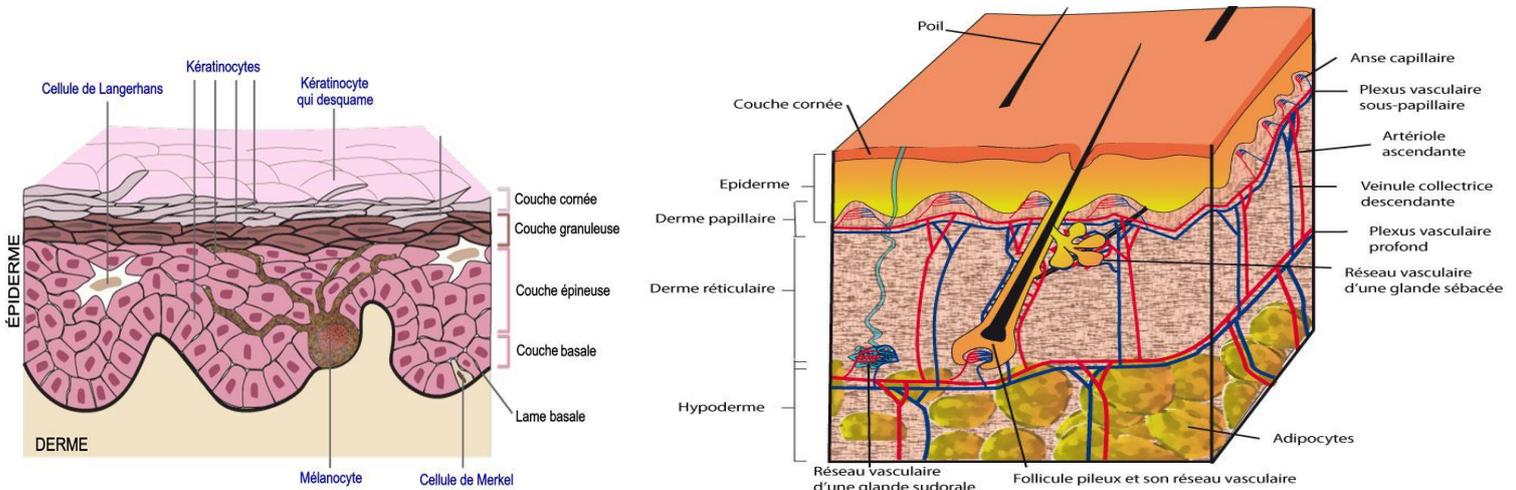


Figure 1.2- Analyse approfondie de l'anatomie de la peau

- 1) **L'épiderme** est la couche externe, principalement constituée de cellules épithéliales stratifiées en plusieurs sous-couches :
 - La couche basale où les cellules se renouvellent par mitose.
 - La couche épineuse où les cellules se différencient et produisent de la kératine.
 - La couche granuleuse où s'accumulent les précurseurs de kératine.
 - La couche cornée externe, aplatie et kératinisée, qui forme une barrière protectrice.
- 2) **Le derme** est la couche intermédiaire, située sous l'épiderme. Il est composé de tissu conjonctif dense contenant vaisseaux, nerfs, follicules pileux, glandes sudoripares et sébacées. Le derme comprend :
 - La couche papillaire superficielle, avec des papilles dermiques qui s'intercalent avec l'épiderme.
 - La couche réticulaire profonde, riche en collagène et élastine pour le soutien et l'élasticité.
- 3) **L'hypoderme** est la couche la plus profonde, principalement adipeuse, qui agit comme isolant thermique et réserve énergétique. Il contient également des vaisseaux sanguins et des terminaisons nerveuses.
- 4) **Autres structures cutanées :**
 - Les follicules pileux : structures tubulaires dans le derme qui produisent des poils.
 - Les glandes sudoripares : produisent la sueur pour réguler la température corporelle.
 - Les glandes sébacées : sécrètent du sébum pour lubrifier la peau et les cheveux.

- Les vaisseaux sanguins : fournissent des nutriments et de l'oxygène aux cellules cutanées, ainsi que régulent la température corporelle.
- Les terminaisons nerveuses : transmettent les sensations tactiles, thermiques et douloureuses.

Une compréhension détaillée de l'anatomie cutanée est essentielle pour le diagnostic et le traitement des maladies de la peau, ainsi que pour la réalisation de procédures dermatologiques telles que les biopsies et les interventions chirurgicales [5].

IV. Classification des maladies de la peau

IV.1. Classification selon l'étiologie

Cette classification se base sur les causes sous-jacentes des maladies de la peau :

- Infectieuses : causées par des agents pathogènes tels que des bactéries (impétigo, folliculite), des virus (herpès, verrues), des champignons (mycoses) ou des parasites (gale, pédiculose).
- Inflammatoires : résultant d'une réponse inflammatoire de la peau, comprenant des conditions telles que l'eczéma, le psoriasis et le lupus érythémateux.
- Allergiques : provoquées par des réactions allergiques à des substances telles que les médicaments, les produits chimiques ou les allergènes environnementaux (dermatite de contact allergique, urticaire).
- Auto-immunes : impliquant une réaction auto-immune contre les composants de la peau, comme dans le cas du pemphigus ou du vitiligo.



Figure 1.3 - Classification selon l'étiologie

IV.2. Classification selon la présentation clinique

Cette classification se base sur l'apparence des lésions cutanées et leur comportement clinique :

- Éruptions cutanées : telles que l'urticaire, la rosacée, ou les éruptions virales.
- Lésions pigmentées : comme les taches de naissance, les taches de vieillesse et le mélanome.

- Lésions nodulaires ou tuméfactives : incluant les kystes, les lipomes et les tumeurs cutanées.
- Lésions ulcéreuses : telles que les ulcères de jambe, les escarres et les ulcères cutanés résultant de maladies sous-jacentes comme le diabète [6].

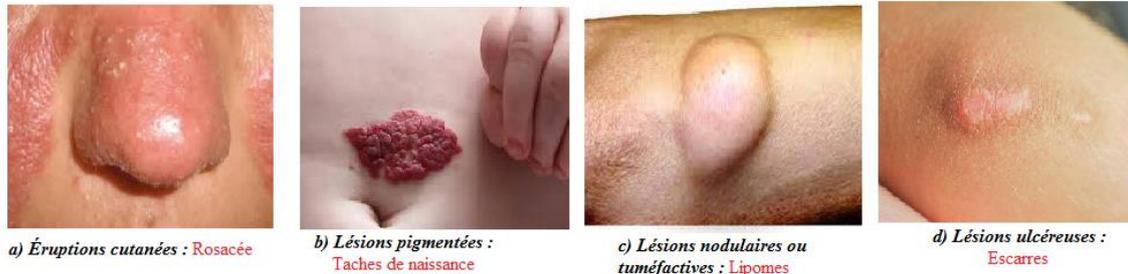


Figure 1.4 - Classification selon la présentation clinique

IV.3. Classification selon la sévérité

Cette classification évalue les maladies de la peau en fonction de leur impact potentiel sur la santé du patient :

- Bénignes : maladies cutanées qui ne présentent pas de risque important pour la santé du patient, telles que les verrues ou l'acné légère.
- Malignes : cancers de la peau comme le carcinome basocellulaire, le carcinome épidermoïde et le mélanome, qui peuvent être potentiellement mortels s'ils ne sont pas traités [7].

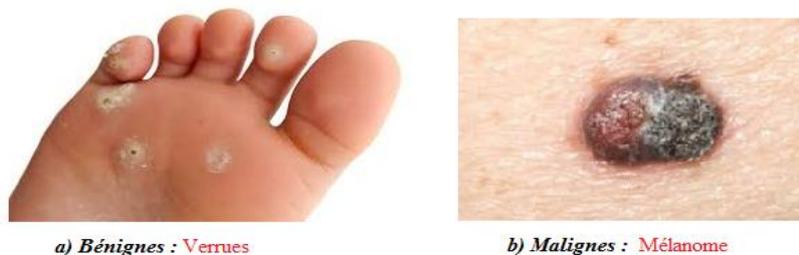


Figure 1.5 - Classification selon la sévérité

IV.4. Classification selon la localisation anatomique

Cette classification se concentre sur les parties spécifiques du corps où les maladies de la peau apparaissent :

- Maladies du cuir chevelu et des cheveux : comme la calvitie (alopécie), la dermatite séborrhéique, et la teigne du cuir chevelu.
- Maladies des ongles : telles que les infections fongiques des ongles (onychomycose), le psoriasis unguéal et les traumatismes des ongles.

- Maladies des muqueuses : telles que le lichen plan buccal, le lichen scléreux génital et la candidose buccale.



Figure 1.6 - Classification selon la localisation anatomique

Cette classification permet aux dermatologues de mieux comprendre et de mieux traiter une gamme variée de maladies cutanées, en adaptant les approches diagnostiques et thérapeutiques en fonction des caractéristiques spécifiques de chaque condition.

V. Principales lésions élémentaires de la peau

La compréhension des lésions élémentaires est essentielle pour identifier les dermatoses. Il est important de distinguer les lésions élémentaires primaires, qui sont les lésions initiales, des lésions élémentaires secondaires, qui sont l'évolution ou la complication de la lésion primaire. Cette distinction permet de mieux comprendre les dermatoses et de prendre des décisions de traitement plus efficaces.

V.1. Lésions primaires



Figure 1.7- Lésions primaires

V.1.1. Lésion visible mais non palpable

La **macule** est une lésion cutanée se présentant sous la forme d'une tache avec une modification de la couleur de la peau. Elle est sans relief, non palpable et mesure moins de 1 cm (au-delà de 1 cm, on parle de « tache »). En fonction de leurs couleurs on peut classer les macules de la manière suivante :

- *Macules colorées* : macules rouges et macules pigmentées.
- *Macules décolorées* : hypochromies et achromies [8].

A) Les macules rouges

Les macules rouges sont très fréquentes, elles sont divisées en 3 types en fonction des effets de la vitropression :

- 1) **L'érythème** correspond à une vasodilatation des vaisseaux du derme qui s'efface entièrement à la vitropression. Il peut être localisé ou généralisé. Pour la forme généralisée, on distingue :
 - *Érythème de type scarlatiniforme* : érythème en plaque diffuse, rouge vif, sans intervalle de peau saine, avec une surface d'aspect granitée à la palpation (ex. Scarlatine). Il peut s'intensifier sur certaines zones, telles que les plis cutanés.
 - *Érythème de type morbilliforme* : érythème caractérisé par des maculo-papules rouges. L'érythème est étendu mais présente de petits intervalles de peau saine, avec une surface lisse et douce (ex. Rougeole).
 - *Érythème de type roséoliforme* : érythème caractérisé par de petites macules rosées, pâles, mal délimitées, avec de larges intervalles de peau saine (ex. Roséole).
 - On parle d'exanthème maculo-papuleux quand l'érythème est associé à une éruption de papules.
- 2) **Les macules vasculaires** correspondent à des anomalies vasculaires superficielles (ex. angiome plan, télangiectasie). Ces macules s'effacent partiellement à la vitropression.
- 3) **Le purpura** correspond à la sortie des globules rouges des vaisseaux du derme. Il se manifeste par une tache rouge sombre qui ne s'efface pas à la vitropression [9].

B) Les macules pigmentées

Les macules pigmentées résultent de l'accumulation de pigments, tels que la mélanine ou le fer, dans l'épiderme ou le derme. Ces macules sont généralement localisées à certaines zones de la peau.

La macule dépigmentée, quant à elle, se manifeste par une tache claire sur la peau. On parle de macule hypochromique lorsque la quantité de pigment mélanique est diminuée, et de macule achromique lorsqu'il y a une absence totale de pigment mélanique.

V.1.2. Lésions visibles et palpables

Ces lésions peuvent être classifiées selon leur contenu en liquide ou en solide.

A) A contenu liquide

Les lésions à contenu liquide comprennent :

- La vésicule est une petite lésion cutanée en relief (moins de 3 mm), apparaissant sur une peau saine ou érythémateuse. Elle contient une sérosité claire et peut avoir une forme arrondie, conique ou ombiliquée, surtout en vieillissant.
- La bulle est une lésion similaire mais de plus grande taille (plus de 5 mm). Elle peut être sous-épidermique ou intra-épidermique et contenir un liquide clair, jaunâtre ou hémorragique. Les bulles se forment sur une peau normale ou érythémateuse.
- La pustule est une lésion en relief, généralement inférieure à 1 cm, contenant du pus. Elle est due à un afflux de polynucléaires neutrophiles dans l'épiderme ou les follicules pilo-sébacés [10].

B) A contenu solide

Les lésions à contenu solide comprennent :

- La papule : Petite lésion solide (<1 cm), légèrement surélevée par rapport à la peau environnante. Une plaque est une grande papule, souvent formée par la coalescence de plusieurs papules. Les types de papules incluent les papules épidermiques (ex. verrue plane), dermiques (ex. urticaire, xanthome), folliculaires et plus rarement la miliaire.
- Le nodule : Lésion solide en relief (>1 cm), arrondie ou ovale, de couleur rose à rouge vif. Le nodule résulte d'une atteinte inflammatoire ou tumorale du derme et/ou de l'hypoderme [11].

V.2. Lésions secondaires

Lésions secondaires comprennent :

- 1) Les croûtes sont des lésions qui apparaissent généralement après une vésicule, bulle ou plaie. Elles ont une consistance variable, de rugueuse à adhérente, et une couleur allant du jaune au rouge foncé. Les croûtes se forment lors de la coagulation de sérosités, de sang ou de pus.
- 2) La cicatrice marque la fin du processus de réparation cutanée après une lésion. Elle apparaît suite à la régénération de tissu fibreux. Il existe différents types de cicatrices :
 - Cicatrice hypertrophique : en relief, bombée, bien délimitée, de couleur de peau. Elle régresse généralement en 1-2 ans.

- Cicatrice chéloïdienne : similaire à l'hypertrophique mais avec des prolongements en pince de crabe. Elle persiste plusieurs années.
- Cicatrice atrophique
- Cicatrice plane



Croûte



Cicatrice hypertrophique

Figure 1.8- Lésions secondaires

VI. Les maladies de la peau

Les maladies de la peau sont nombreuses et variées, et peuvent être causées par des facteurs tels que des infections, des allergies, des maladies auto-immunes, des changements hormonaux, des facteurs environnementaux et des traitements médicamenteux. Voici quelques exemples de maladies de la peau détectées dans notre étude :

VI.1. Kératose actinique

La kératose actinique est une lésion cutanée bénigne qui se développe à partir des kératinocytes de l'épiderme. Elle affecte fréquemment les parties du corps les plus exposées au soleil, comme le visage, les oreilles, le décolleté, le dos des mains ou les zones dégarnies du cuir chevelu.

Elle peut prendre des formes très différentes, notamment sous forme de taches ou de papules squameuses ou cornées, avec des couleurs variées, allant de la couleur chair à jaune, rougeâtre ou brunâtre [12].



Figure 1.9- Kératose actinique

VI.2. Carcinome basocellulaire

Le carcinome basocellulaire est un cancer de la peau qui se développe à partir de la couche basale de l'épiderme. Il est le plus fréquent des cancers de la peau, représentant 70 % des cas, et est souvent lié à l'exposition chronique au soleil [13].

Il se manifeste généralement sous la forme d'une zone de peau épaisse, rouge ou brune, qui peut se transformer en un nodule d'aspect laiteux ou ressemblant à une perle, parcouru de petits vaisseaux sanguins [12].



Figure 1.10 - Carcinome basocellulaire

VI.3. Dermatofibrome

Le dermatofibrome est une lésion cutanée bénigne qui se développe à partir des cellules de la couche basale de l'épiderme. Elle est souvent liée à des traumatismes cutanés répétés et peut prendre des formes variées, comme des taches, des papules ou des nodules [14].



Figure 1.11 - Dermatofibrome

VI.4. Mélanome

Le mélanome est un type de cancer de la peau qui se développe à partir des cellules pigmentaires de la peau, les mélanocytes. Il est souvent lié à l'exposition chronique au soleil et peut prendre des formes variées, comme des taches, des papules ou des nodules [14].



Figure 1.12- Mélanome

VI.5. Nævus

Un nævus est une tumeur bénigne qui se développe à partir des cellules pigmentaires de la peau, les mélanocytes. Elle est souvent présente à la naissance et peut prendre des formes variées, comme des taches, des papules ou des nodules, et est souvent présente à la naissance [14].



Figure 1.13- Nævus

VI.6. Kératose bénigne pigmentée

La kératose bénigne pigmentée est une lésion cutanée bénigne qui se développe à partir des kératinocytes de l'épiderme. Elle est souvent liée à l'exposition chronique au soleil et peut prendre des formes variées, comme des taches, des papules ou des nodules [14].



Figure 1.14 - Kératose bénigne pigmentée

VI.7. Kératose séborrhéique

La kératose séborrhéique est une lésion cutanée bénigne qui se développe à partir des kératinocytes de l'épiderme. Elle est souvent liée à des problèmes de sécrétion glandulaire

excessive et peut prendre des formes variées, comme des taches, des papules ou des nodules [14].



Figure 1.15 - Kératose séborrhéique

VI.8. Carcinome épidermoïde

Le carcinome épidermoïde, anciennement appelé carcinome spinocellulaire, est un cancer de la peau qui se développe à partir des cellules épidermiques. Il est souvent lié à des expositions solaires chroniques, des antécédents de radiothérapie, des cicatrices chroniques, des états inflammatoires chroniques et des infections papillomavirus [15].



Figure 1.16 - Carcinome épidermoïde

VI.9. Lésion vasculaire

Les lésions vasculaires sont des tumeurs bénignes qui se développent à partir des vaisseaux sanguins. Elles peuvent prendre des formes variées, comme des angiomes, des angiokératomes, des granulomes pyogéniques et des hémorragies [14].

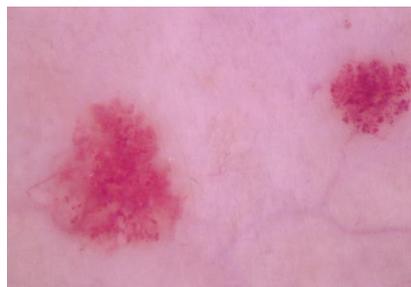


Figure 1.17- Lésion vasculaire

VI.10. Kératoses actiniques et carcinome intraépithélial / Maladie de Bowen

Les kératoses actiniques sont des lésions cutanées précancéreuses qui peuvent évoluer vers un carcinome intraépithélial ou une maladie de Bowen, un type de carcinome épidermoïde.

Les kératoses actiniques sont souvent retrouvées de façon contiguë avec des carcinomes spinocellulaires, et les deux ont les mêmes altérations génétiques et morphologie.

Le diagnostic des kératoses actiniques est clinique, et le traitement peut inclure des techniques destructrices, des médicaments et des phototherapiques [16].



Figure 1.18 - Maladie de Bowen

VII. Examens cliniques du diagnostic des maladies de la peau

Un diagnostic précis est indispensable pour évaluer la cause et déterminer le traitement adapté. Le diagnostic des maladies de la peau peut être effectué par :

VII.1. Anamnèse et examen clinique

Le dermatologue recueille l'historique médical et les circonstances d'apparition de la maladie auprès du patient lors d'un interrogatoire détaillé (antécédents familiaux, expositions, autres maladies, voyages récents, etc.).

Il procède ensuite à un examen clinique précis et détaillé de la peau, des muqueuses, du cuir chevelu et des ongles, observant attentivement la taille, la forme, la couleur et la localisation des lésions.

Des techniques comme la dermatoscopie (loupe avec éclairage), la lumière de Wood ou la diascopie (appui d'une lame sur la lésion) peuvent être utilisées pour révéler certains détails [17].

VII.2. Examens complémentaires

Des examens de laboratoire non systématiques peuvent être réalisés pour confirmer ou étayer le diagnostic, comme des prélèvements par grattage cutané en cas de suspicion de mycose ou de gale.

La biopsie cutanée est l'examen le plus fréquemment pratiqué, avec prélèvement d'un fragment de peau contenant la lésion pour analyse en laboratoire, notamment pour les cancers de la peau.

Le test de Tzanck permet de diagnostiquer certaines maladies virales comme l'herpès et le zona en analysant le liquide d'une cloque [17].

VII.3. Diagnostic final

Pour la plupart des maladies de peau, le diagnostic peut être posé par l'examen clinique et l'anamnèse. Mais pour certaines pathologies rares, les examens complémentaires aident surtout à orienter le diagnostic.

En cas de doute ou de maladie rare, le dermatologue peut orienter le patient vers des établissements spécialisés et le mettre en relation avec des experts pour affiner le diagnostic et la thérapeutique [17].

VIII. L'intelligence artificielle dans le diagnostic des maladies de la peau

L'intelligence artificielle transforme le diagnostic dermatologique en analysant des images et des données cliniques pour identifier les affections cutanées [18].

VIII.1. Analyse d'images et de données: vers un diagnostic plus précis et précoce

L'intelligence artificielle révolutionne le diagnostic des maladies de la peau en analysant des images et des données cliniques pour identifier les affections cutanées [19] [20].

Les algorithmes d'apprentissage automatique et de vision par ordinateur analysent les images dermatoscopiques et les photographies de lésions cutanées, extrayant des caractéristiques telles que la couleur, la forme, la texture et la taille. Ces caractéristiques sont ensuite utilisées pour classifier les lésions et aider à établir un diagnostic [19] [20].

L'IA permet une analyse objective, reproductible et rapide des lésions cutanées, détectant des caractéristiques subtiles que l'œil humain pourrait manquer. Cela conduit à un diagnostic plus précis, en particulier pour le mélanome, et à une détection plus précoce des cancers de la peau [19] [20].

VIII.2. Analyse des caractéristiques cliniques et aide au diagnostic différentiel

L'IA analyse également les caractéristiques cliniques des lésions cutanées, telles que la taille, la forme, la couleur et les symptômes associés [21]. Ces informations sont comparées à une base de données de maladies cutanées pour générer une liste de diagnostics potentiels [22].

Les modèles d'IA attribuent une probabilité à chaque diagnostic différentiel, aidant les dermatologues à affiner leur diagnostic et à formuler un plan de prise en charge adapté [23].

VIII.3. Avantages de l'IA dans le diagnostic dermatologique

L'IA améliore la précision [24] et la rapidité du diagnostic [21], en fournissant une analyse objective et en détectant des caractéristiques subtiles. Elle permet également une détection précoce des cancers de la peau, en particulier du mélanome [22].

VIII.4. Amélioration continue grâce à l'apprentissage automatique

Les modèles d'IA s'améliorent continuellement grâce à l'apprentissage automatique, en intégrant de nouvelles données et en affinant leurs algorithmes. Cela garantit que l'IA reste à la pointe du progrès en matière de diagnostic dermatologique [18].

L'IA s'impose comme un outil indispensable dans le domaine de la dermatologie, améliorant le diagnostic, la prise en charge des patients et les résultats thérapeutiques [24].

IX. Conclusion

Le diagnostic des maladies de la peau est un processus complexe qui nécessite une compréhension approfondie des diverses affections cutanées et des technologies avancées utilisées pour leur identification.

L'intelligence artificielle joue un rôle croissant dans ce domaine, en permettant une détection plus précoce et plus précise des pathologies, ainsi qu'une amélioration continue des traitements et des soins de santé.

Les dermatologues et les professionnels de la santé peuvent utiliser les outils d'IA pour analyser des images et des données, détecter des caractéristiques subtiles, et prendre des décisions éclairées. De plus, l'IA peut aider à la télémédecine et au dépistage à distance, ce qui permet une meilleure accessibilité et une meilleure prise en charge des patients.

Le chapitre suivant explore les travaux de l'état de l'art sur les différentes méthodes proposées pour la classification et la reconnaissance des maladies de la peau.

Chapitre 2 - Apprentissage profond pour la classification des maladies de la peau

I. Introduction

La classification des maladies de la peau est un domaine fondamental en dermatologie, nécessitant une compréhension approfondie des diverses affections cutanées et des technologies avancées utilisées pour leur identification. Avec l'avancement de l'intelligence artificielle et des technologies de l'information, de nouvelles approches ont été développées pour améliorer la classification des maladies cutanées. Ces méthodes incluent l'utilisation d'algorithmes d'apprentissage automatique pour extraire des caractéristiques spécifiques des lésions cutanées, ainsi que l'emploi de réseaux de neurones profonds, tels que les réseaux de neurones convolutifs (CNN), pour analyser des images dermatoscopiques et des données cliniques.

Notre chapitre commence par une introduction aux principes fondamentaux de l'apprentissage automatique dans la section 2. La section suivante approfondit ces concepts en se concentrant sur les techniques d'apprentissage profond. Nous examinons ensuite les réseaux de neurones convolutifs et leur fonctionnement. Le chapitre se poursuit en mettant en lumière les dernières avancées dans l'utilisation de l'apprentissage profond pour la classification automatique des affections cutanées. Nous terminons ce chapitre par une conclusion.

II. Apprentissage automatique

L'apprentissage automatique, également connu sous le nom de machine Learning, est une branche de l'intelligence artificielle qui utilise des méthodes mathématiques pour permettre à une machine d'apprendre et de tirer des connaissances à partir d'un ensemble de données, afin d'effectuer automatiquement des tâches spécifiques. Cette technologie est particulièrement utile dans des situations où les approches algorithmiques traditionnelles ou l'intervention humaine sont inefficaces ou impossibles [25] [26].

Les méthodes d'apprentissage automatique peuvent être divisées en plusieurs catégories, notamment [25] [26]:

- ***Apprentissage supervisé*** : où le modèle est entraîné avec des données étiquetées pour apprendre à prédire des résultats spécifiques. Exemples : réseaux de neurones, arbres de décision.
- ***Apprentissage non supervisé*** : où le modèle est entraîné avec des données non étiquetées pour identifier des patterns et des structures dans les données. Exemple : clustering.

- **Apprentissage semi-supervisé** : où le modèle est entraîné avec des données partiellement étiquetées pour apprendre à prédire des résultats spécifiques. Exemples : Self-Training, Co-Training.
- **Apprentissage par transfert** : où le modèle est entraîné avec des données de domaine similaire pour apprendre à généraliser à un nouveau domaine. Exemples : réseaux de neurones pré-entraînés (VGG16, ResNet50, etc.), transfert de connaissances.
- **Apprentissage par renforcement** : où le modèle est entraîné en interagissant avec un environnement pour apprendre à prendre des décisions optimales. Exemples : agents intelligents, réseaux de neurones avec des couches de décision.

Ces méthodes peuvent être utilisées dans divers domaines, notamment la médecine, la finance, la gestion des ressources humaines, etc.

III. Apprentissage profond

L'apprentissage profond, également connu sous le nom de *Deep Learning*, est une branche de l'intelligence artificielle qui permet à une machine d'apprendre de manière autonome à partir de données brutes, sans nécessiter d'intervention humaine dans le calcul et la sélection des caractéristiques pertinentes. Cette technique est développée à partir de l'apprentissage automatique, qui nécessite une intervention humaine pour sélectionner les caractéristiques pertinentes et ajuster les paramètres du modèle [27].

La figure suivante présente la relation entre l'intelligence artificielle, l'apprentissage automatique et l'apprentissage profond :

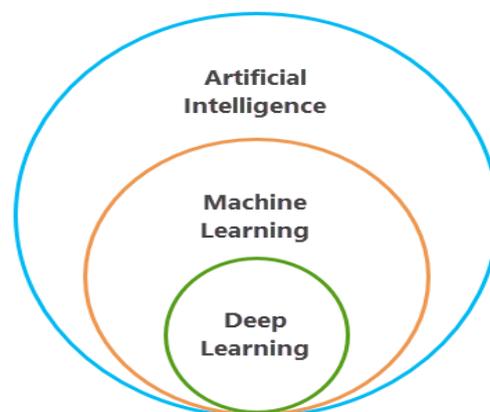


Figure 2.1- Illustration de la relation entre l'intelligence artificielle, le machine Learning et le Deep Learning.

L'apprentissage profond utilise des réseaux neuronaux pour apprendre et améliorer les performances de manière autonome. Les réseaux neuronaux sont composés de plusieurs couches interconnectées, chaque couche appliquant une fonction spécifique sur les données d'entrée. Les couches peuvent être divisées en plusieurs types, notamment [28]:

- *Couche d'entrée* : où les données d'entrée sont traitées pour être prêtes à être utilisées par le réseau neuronal.
- *Couches cachées* : où les données sont traitées pour extraire des patterns et des caractéristiques spécifiques.
- *Couche de sortie* : où les résultats finaux sont générés à partir des données traitées dans les couches précédentes.

Les algorithmes d'apprentissage profond utilisent directement les images comme entrée, sans passer par l'extraction manuelle de caractéristiques. Ils reconnaissent et apprennent automatiquement des caractéristiques de complexité variable pour entraîner un modèle spécifique à la tâche. Ces méthodes ont révolutionné la vision par ordinateur dans de nombreux domaines, notamment la reconnaissance faciale, la détection d'objets et le traitement d'images. En médecine, elles résolvent des problèmes complexes que les médecins ont du mal à gérer manuellement [27].

Les progrès de l'apprentissage profond sont dus à l'augmentation de la puissance de calcul et à la création de grandes bases de données annotées. Les réseaux de neurones convolutifs sont les modèles les plus performants pour la segmentation et la classification automatique d'images médicales [27].

L'apprentissage profond appliqué aux images médicales permet d'extraire automatiquement les caractéristiques pertinentes sans intervention humaine, entraînant des modèles performants de reconnaissance de formes et de classification. Cela ouvre la voie à de nombreuses applications en diagnostic assisté par ordinateur [27].

IV. Réseaux de neurones convolutifs

Les réseaux de neurones convolutifs sont des architectures avancées de réseaux de neurones artificiels, composées de plus de cinq couches cachées. Ces réseaux comprennent plusieurs couches interconnectées qui apprennent à représenter les données à divers niveaux d'abstraction. Les couches initiales extraient des caractéristiques simples des données d'entrée, tandis que les couches ultérieures combinent ces caractéristiques pour générer des représentations plus complexes. Ces modèles ont significativement amélioré les performances

dans l'analyse d'images médicales et la détection de pathologies, surpassant les capacités humaines pour certaines tâches complexes. Les CNN utilisent des algorithmes de rétro-propagation pour ajuster leurs paramètres internes et optimiser l'apprentissage [27].

Un CNN est constitué de différentes couches empilées, principalement des couches de convolution et de pooling. La couche de convolution, élément central du CNN, applique des filtres de petite taille pour extraire les caractéristiques de l'image d'entrée. Elle est souvent suivie d'une couche de pooling qui réduit la dimension de l'image en conservant les informations essentielles. En alternant ces couches, les CNN produisent une hiérarchie de caractéristiques de l'image, allant des bords et des lignes simples aux motifs et formes complexes [27].

Après l'extraction des caractéristiques, la sortie de la dernière couche de convolution est aplatie en un vecteur de caractéristiques, utilisé comme entrée pour une ou plusieurs couches entièrement connectées. Ces couches sont utilisées pour la classification ou la segmentation des images. La dernière couche du réseau est souvent une couche de classification utilisant une fonction d'activation pour produire des probabilités de classe. Le réseau est entraîné en ajustant les poids des connexions entre les neurones via un algorithme de rétro-propagation du gradient, afin de minimiser la fonction de perte [27].

La figure suivante illustre les différentes couches d'un CNN, détaillant la structure et le fonctionnement de ces réseaux complexes.

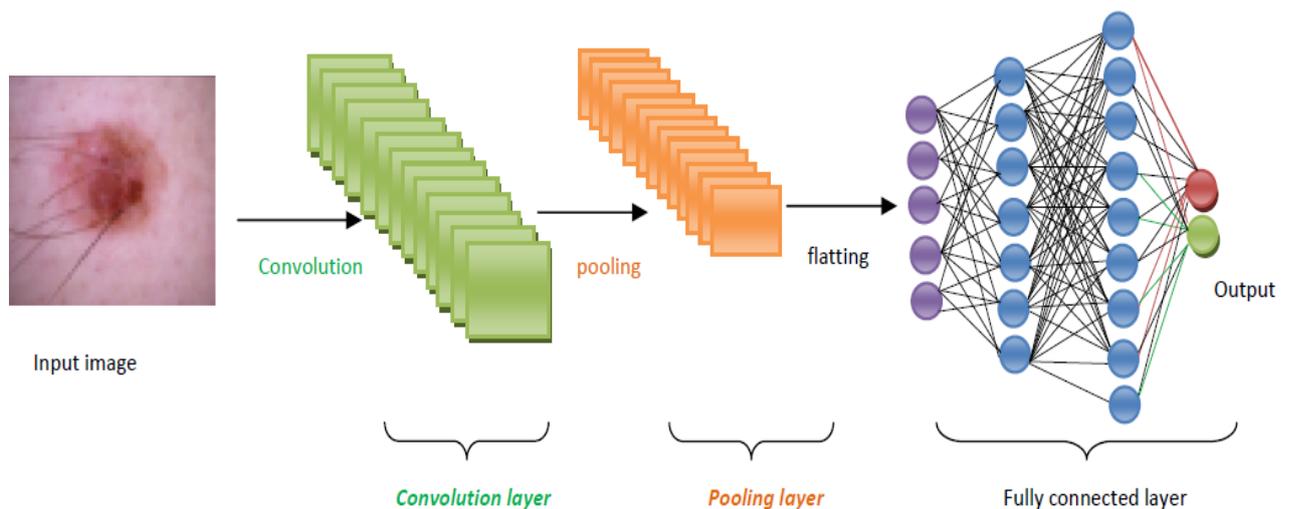


Figure 2.2- Illustration d'un exemple de CNN pour la classification des images de maladies de la peau.

Dans la section suivante, nous allons brièvement expliquer le rôle de chaque couche dans un réseau de neurones profond.

IV.1. Couches des réseaux neuronaux convolutifs

Les couches d'un réseau neuronal convolutif constituent les éléments clés qui permettent au modèle de traiter et d'analyser des images de manière complexe et intelligente. Chaque couche joue un rôle crucial dans le traitement des données, et elles sont classées selon leurs fonctions spécifiques [27].

Typiquement, un CNN se compose de quatre types de couches principales : la couche de convolution, la couche d'activation (ou correction), la couche de pooling et la couche entièrement connectée (illustrée à la figure 2.2). D'autres couches peuvent également être présentes, telles que la couche de normalisation et la couche de régularisation (dropout) [27].

Les sections suivantes fournissent une description détaillée des différentes couches employées dans la construction des CNN.

IV.1.1. Couche de Convolution

La couche de convolution est un composant essentiel des CNN, utilisée pour extraire des caractéristiques locales des images en appliquant divers filtres de petite taille (généralement 3x3 ou 5x5). Chaque filtre effectue une opération de convolution sur l'image, multipliant ses coefficients par les valeurs de l'image et additionnant les résultats pour générer une nouvelle valeur. Cette nouvelle valeur est stockée dans une carte de caractéristiques (ou feature map en anglais). La première couche de convolution capture des caractéristiques de bas niveau, tandis que les couches suivantes extraient des caractéristiques de haut niveau. Les filtres sont des matrices de poids initialisés aléatoirement et ajustés durant l'entraînement pour mieux extraire les caractéristiques pertinentes. La figure suivante illustre de manière claire l'opération de convolution appliquée à la reconnaissance d'images [27].

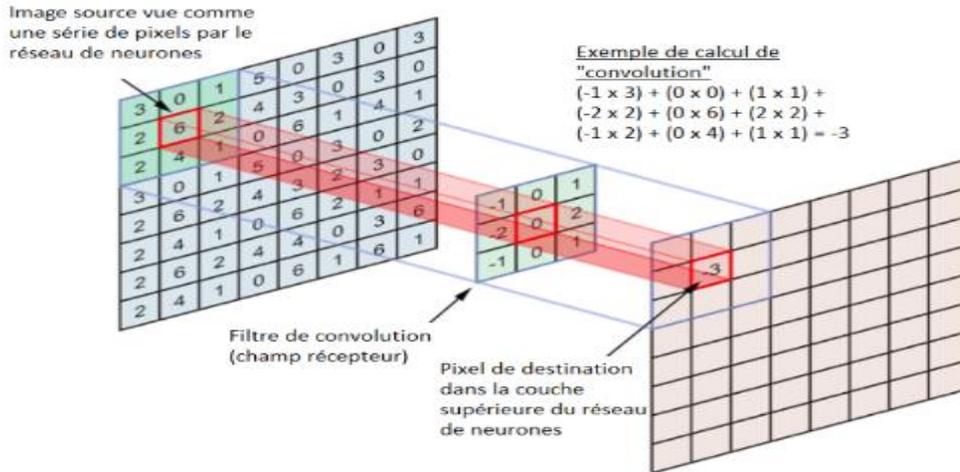


Figure 2.3- Illustration d'un exemple d'opération de convolution appliquée à la reconnaissance d'images.

Pour chaque couche de convolution, quatre hyper-paramètres doivent être définis au départ : la taille des filtres, le nombre de filtres, le pas (stride) et le remplissage à zéros (zero padding) [27].

- *Taille des filtres* : Plus la taille des filtres est petite et le nombre de couches de convolution est élevé, meilleure est la performance.
- *Nombre de filtres* : Contrôle le nombre de cartes de caractéristiques produites. Plus il y a de filtres, plus la représentation de l'image est complexe.
- *Pas (stride)* : Nombre de pixels par lesquels le filtre se déplace après chaque calcul. Augmenter le pas réduit la taille de la sortie.
- *Remplissage (zero padding)* : Ajoute des zéros aux bords de l'image pour conserver la même taille d'entrée après la convolution.

L'ajustement précis de ces hyper-paramètres est crucial pour optimiser les performances du modèle, car certaines configurations peuvent fonctionner plus efficacement que d'autres.

La couche de convolution joue un rôle vital dans l'extraction des caractéristiques des images, avec des filtres ajustés pour capturer différentes caractéristiques locales, facilitant ainsi une analyse détaillée et une classification précise [27].

IV.1.2. Fonctions d'activation

Les fonctions d'activation sont appliquées après chaque couche de convolution pour introduire de la non-linéarité dans le modèle, permettant ainsi de modéliser des relations complexes entre les entrées et les sorties. Les plus couramment utilisées incluent : ReLU et Softmax [27].

1) Fonction Unité Linéaire Rectifiée (ReLU)

ReLU (Rectified Linear Unit en anglais) est une fonction d'activation standard dans les architectures de Deep Learning en raison de sa simplicité et de son efficacité. ReLU est définie par [27] :

$$ReLU(x) = \max(0, x) \tag{2.1}$$

Cette fonction remplace toutes les valeurs négatives par zéro, ce qui peut réduire le nombre de neurones actifs et, parfois, affecter la performance du réseau. La figure suivante montre un exemple de principe de fonctionnement du ReLU.

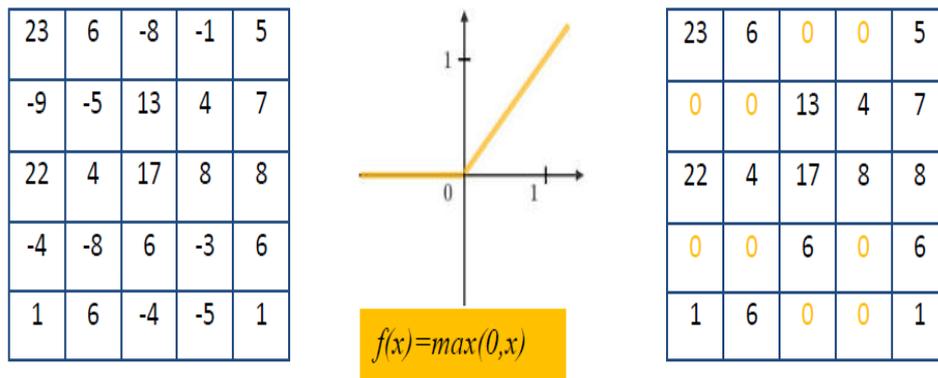


Figure 2.4 - Le principe de fonctionnement du ReLU.

2) Fonction Softmax

La fonction Softmax est couramment utilisée comme dernière couche dans les réseaux de neurones convolutifs pour la classification multi-classes. Elle transforme les sorties en une distribution de probabilités normalisées sur plusieurs classes, facilitant ainsi l'interprétation des résultats. La formule de la fonction Softmax pour une entrée z_i dans un vecteur z est donnée par [27]:

$$Softmax(z) = e^{z_i} / \sum_{j=1}^k e^{z_j} \tag{2.2}$$

IV.1.3. Couche de pooling

Le pooling, ou sous-échantillonnage, est une composante essentielle des CNN. Il réduit la taille spatiale (hauteur et largeur) des images intermédiaires (cartes de caractéristiques) tout en conservant les informations les plus importantes. Cela diminue le nombre de paramètres et le temps de calcul nécessaires, tout en aidant à prévenir le sur-apprentissage et à augmenter la robustesse du modèle. Une couche de pooling est généralement placée après une couche de convolution. Le processus de pooling divise l'image d'entrée en petites fenêtres de taille $n*n$

pixels sans chevauchement (sous-échantillonnage) et sélectionne une seule valeur par fenêtre selon le type de pooling choisi. Les tailles de fenêtre courantes sont 2*2 ou 3*3 [27].

Il existe deux types principaux de pooling [27] :

1) **Max-pooling** : Retient la valeur maximale de chaque fenêtre dans la carte des caractéristiques, étant le plus couramment utilisé dans les CNN (figure 2.5).

2) **Average pooling** : Conserve la valeur moyenne de chaque fenêtre (figure 2.5).

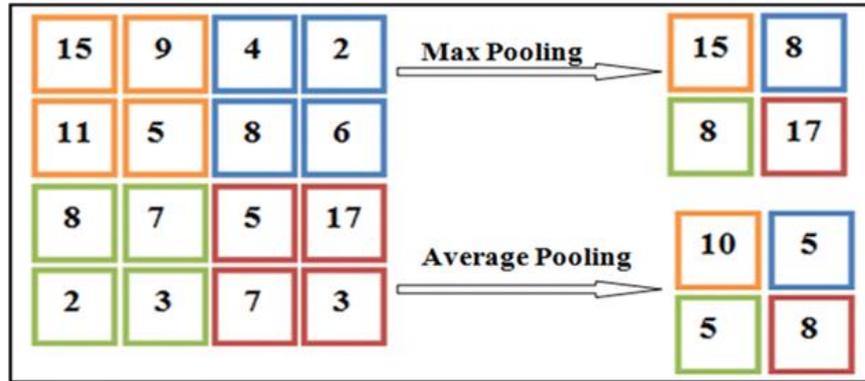


Figure 2.5- Processus de max et average pooling avec fenêtre de taille 2x2 et pas 2.

IV.1.4. Couche entièrement connectée

La couche entièrement connectée (Fully connected layer en anglais), située à la fin d'un CNN, transforme les caractéristiques extraites par les couches précédentes en un vecteur de sortie pour des tâches de classification ou de régression. Chaque neurone de la FC est relié à tous les neurones de la couche précédente, semblable à un réseau de neurones artificiels. Le nombre de neurones dans cette couche dépend de la tâche de classification ou de prédiction. Suivie d'une fonction d'activation, comme Softmax, la couche normalise les sorties pour produire une distribution de probabilités, permettant de sélectionner la classe avec la plus haute probabilité comme prédiction finale [27].

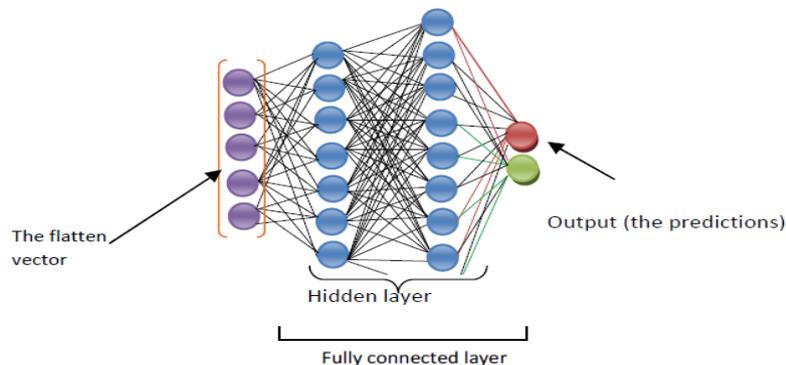


Figure 2.6- Couche entièrement connectée

IV.1.5. Couche de normalisation

La couche de normalisation par lot (batch normalization en anglais) est une technique de régularisation utilisée pour accélérer la convergence et améliorer les performances des modèles en apprentissage profond. Elle normalise les activations en calculant la moyenne et l'écart type pour chaque mini-lot, stabilisant ainsi le processus d'apprentissage et réduisant le nombre d'époques nécessaires. Cette méthode, souvent combinée avec d'autres régularisations comme le dropout, aide à réduire le sur-apprentissage et à améliorer la précision [27].

IV.1.6. Couche de Dropout

Le dropout est une technique de régularisation pour éviter le sur-apprentissage dans les réseaux de neurones profonds. Pendant l'entraînement, il désactive aléatoirement un certain nombre de neurones et leurs connexions à chaque époque, selon une probabilité p (souvent $p=0.5$). Cela force les neurones à être individuellement utiles en réduisant leur interdépendance. Cette méthode est désactivée lors de la phase de test, où tous les neurones sont activés et les sorties sont ajustées pour compenser les effets du dropout [27].

IV.1.7. Fonction de perte

La fonction de perte, aussi appelée fonction d'erreur ou de coût, mesure la différence entre les prédictions du modèle et les valeurs réelles (étiquettes). Elle produit une valeur scalaire représentant l'erreur moyenne du modèle sur les données d'entraînement, utilisée pour ajuster les paramètres du modèle via un algorithme d'optimisation afin de minimiser l'erreur. Les types de fonctions de perte varient selon les tâches : MSE (Mean Squared Error) pour la régression, et l'entropie croisée pour la classification. L'entropie croisée, souvent combinée avec la fonction Softmax, transforme les sorties du réseau en une distribution de probabilités normalisées [27].

IV.1.8. Algorithmes d'optimisation

Les algorithmes d'optimisation ajustent les poids et les biais des neurones pour minimiser la fonction de perte. Leur rôle est crucial en apprentissage profond pour optimiser les performances du modèle. Les principaux algorithmes incluent la descente de gradient, la descente de gradient stochastique, avec Momentum et Adam [27].

1) *Descente de gradient (GD)* : Cette technique itérative calcule le gradient de la fonction de coût sur l'ensemble des données et met à jour les paramètres dans la direction de la pente la

plus forte, visant le minimum global. Un hyper-paramètre appelé taux d'apprentissage détermine la longueur du pas à chaque itération [27].

2) *Descente de gradient stochastique (SGD)* : Variante de la GD, elle met à jour les poids sur chaque échantillon des données d'entraînement plutôt que sur l'ensemble complet. Cela peut accélérer le processus mais peut aussi provoquer des minimax locaux dans la fonction de perte [27].

3) *SGD avec Momentum (SGDM)* : Améliore le SGD en introduisant un terme de momentum qui accumule les gradients précédents via une moyenne mobile, permettant des mises à jour de poids plus significatives en cas de forte pente et accélérant ainsi la convergence [27].

4) *ADAM (Adaptive Moment Estimation)* : Combine les idées de SGDM avec deux moments d'ordre. Il garde une moyenne mobile des gradients précédents et une autre moyenne mobile des gradients au carré, ajustant automatiquement le taux d'apprentissage. Cette méthode efficace permet des mises à jour de poids et de biais rapides et fiables, réduisant le temps d'apprentissage et offrant robustesse, ce qui en fait un choix populaire [27].

Le choix de l'algorithme dépend de la tâche, de la taille des données et de l'architecture du modèle utilisé.

IV.1.9. Les Hyper-paramètres en Apprentissage Profond

Les hyper-paramètres sont des paramètres cruciaux en apprentissage profond, déterminés avant l'entraînement d'un modèle pour optimiser ses performances. Voici les principaux [27]:

- *Taux d'apprentissage* : Contrôle la taille des ajustements des poids. Un taux trop élevé peut rendre le modèle instable, tandis qu'un taux trop bas peut ralentir la convergence.
- *Nombre d'époques* : Indique combien de fois le modèle passe sur les données d'entraînement. Trop peu d'époques peuvent entraîner un sous-apprentissage, tandis que trop d'époques peuvent entraîner un sur-apprentissage.
- *Taille du mini-lot* : Nombre d'échantillons pour chaque mise à jour des poids. Une taille trop petite peut causer de l'instabilité, tandis qu'une taille trop grande peut ralentir la convergence.
- *Nombre de couches et taille du réseau* : La profondeur et la structure du modèle affectent ses performances. Une architecture trop simple peut entraîner un sous-apprentissage, alors qu'une architecture trop complexe peut mener à un sur-apprentissage.
- *Choix de la fonction de coût* : Impacte la capacité de généralisation du modèle.

- *Choix de l'algorithme d'optimisation* : Détermine comment les poids sont ajustés et peut améliorer l'efficacité de l'apprentissage.

Ces hyper-paramètres doivent être choisis avec soin pour obtenir les meilleurs résultats possibles. La suite de la discussion abordera les architectures populaires de segmentation et de classification en apprentissage profond.

IV.2. Architectures de Classification les Plus Connues

Les architectures de classification en apprentissage profond ont évolué rapidement, offrant des solutions de plus en plus performantes pour diverses tâches de reconnaissance d'images. Voici quelques-unes des plus connues :

IV.2.1. Architecture VGG16

VGGNet, une architecture de réseaux de neurones convolutifs élaborée par le groupe Visual Geometry Group (VGG) de l'université d'Oxford en 2014, est spécifiquement conçue pour la classification d'images. Elle se compose de cinq blocs de convolution, exploitant des filtres de taille 3x3 avec une profondeur progressive de 64, 128, 256, 512 et 512. Chaque couche convolutive est suivie par la fonction d'activation ReLU, et des couches de max pooling de taille 2x2 et d'un pas de 2 sont insérées entre les blocs pour réduire la dimension spatiale. En outre, trois couches entièrement connectées avec un nombre de neurones de 4096, 4096 et 1000 respectivement, suivies de la fonction d'activation Softmax, sont utilisées pour la classification [27].

Entraînée sur plus d'un million d'images provenant de la base de données ImageNet, cette architecture permet la classification d'images en 1000 catégories d'objets distinctes. Les images d'entrée doivent être des images couleur RVB de taille 224x224x3. Parmi les versions les plus réputées de ce modèle figurent VGG16 et VGG19, qui comportent respectivement 16 et 19 couches de poids, combinant à la fois des couches de convolution et des couches entièrement connectées [27].

Concernant VGG16, il est constitué de 13 couches de convolution et de 3 couches entièrement connectées. Les deux premiers blocs convolutifs comprennent deux couches de convolution, suivies chacune de ReLU, ainsi qu'une couche de max pooling de taille 2x2. Les trois autres blocs intègrent trois couches de convolution, accompagnées d'une couche de max pooling dans chacun d'eux. La sortie de ces blocs est ensuite dirigée vers les trois couches entièrement connectées afin de produire la sortie finale [27].

VGG19, une extension de VGG16, se distingue par l'ajout de trois couches de convolution supplémentaires, portant ainsi le total à 16 couches convolutionnelles et 3 couches entièrement connectées. Les deux premiers blocs de convolution sont similaires à ceux de VGG16, tandis que les trois blocs suivants comportent chacun une couche de convolution supplémentaire par rapport à VGG16 [27].

Cette architecture renforcée de VGG19 offre une robustesse accrue et des performances améliorées par rapport à VGG16, grâce à sa plus grande profondeur. Cette profondeur accrue permet une extraction de caractéristiques plus complexes, ce qui rend le modèle plus adaptable aux bases de données plus vastes et plus complexes. Cependant, il convient de noter que cette profondeur supplémentaire peut entraîner des temps d'entraînement plus longs et exiger des ressources computationnelles et une mémoire plus importante [27].

L'architecture VGGNet, largement reconnue et utilisée dans la littérature, met en évidence l'importance critique de la profondeur du réseau pour obtenir de bonnes performances en classification d'images [27].

La figure suivante présente la structure comparative des deux architectures VGG16 et VGG19, mettant en évidence la différence significative entre elles en termes du nombre de couches de convolution [27].



Figure 2.7- Architectures VGG16 et VGG19

IV.2.2. Architecture ResNet

He et al. ont présenté en 2016 un réseau neuronal convolutif nommé ResNet (Deep Residual Networks), basé sur le concept de bloc résiduel, dans le but de résoudre le problème de dégradation du gradient, fréquemment rencontré dans les réseaux de grande profondeur. Ce problème survient lorsque la précision des réseaux commence à saturer, puis diminue rapidement en raison de la diminution du gradient. Dans l'architecture ResNet, les auteurs ont

introduit des blocs résiduels, formant des connexions directes entre la sortie de la couche précédente et celle de la couche actuelle. ResNet-50 est l'un des types les plus célèbres de l'architecture ResNet [29].

ResNet50 est un modèle de pointe pour la classification d'images, renommé pour sa capacité à traiter de grands ensembles de données avec des performances exceptionnelles. Son innovation majeure réside dans l'utilisation de connexions résiduelles, qui permettent au réseau d'apprendre des fonctions résiduelles, facilitant ainsi l'apprentissage de structures beaucoup plus profondes sans rencontrer de problèmes liés à la disparition des gradients [30].

L'architecture de ResNet50 peut être divisée en quatre composants principaux [30]:

- *Couches de convolution* : Ces couches extraient les caractéristiques clés de l'image d'entrée, telles que les bords, les textures et les formes. Elles sont suivies de normalisation par lots, d'une activation ReLU et de max pooling pour réduire les dimensions spatiales tout en préservant les informations importantes.
- *Bloc d'identité* : Ce bloc transmet l'entrée à travers plusieurs couches de convolution et ajoute ensuite l'entrée à la sortie. Cette technique permet au réseau d'apprendre des fonctions résiduelles, améliorant ainsi la capacité de généralisation.
- *Bloc de convolution* : Similaire au bloc d'identité, ce bloc intègre une couche de convolution 1x1 pour réduire le nombre de filtres avant d'appliquer une convolution 3x3.
- *Couches entièrement connectées* : Ces couches réalisent la classification finale. La sortie est soumise à une fonction d'activation softmax pour produire les probabilités associées à chaque classe.

Grâce à cette architecture bien conçue, ResNet-50 est capable de construire des réseaux très profonds tout en évitant les problèmes liés à la disparition des gradients, ce qui en fait un choix privilégié pour de nombreuses tâches de classification d'images [30].

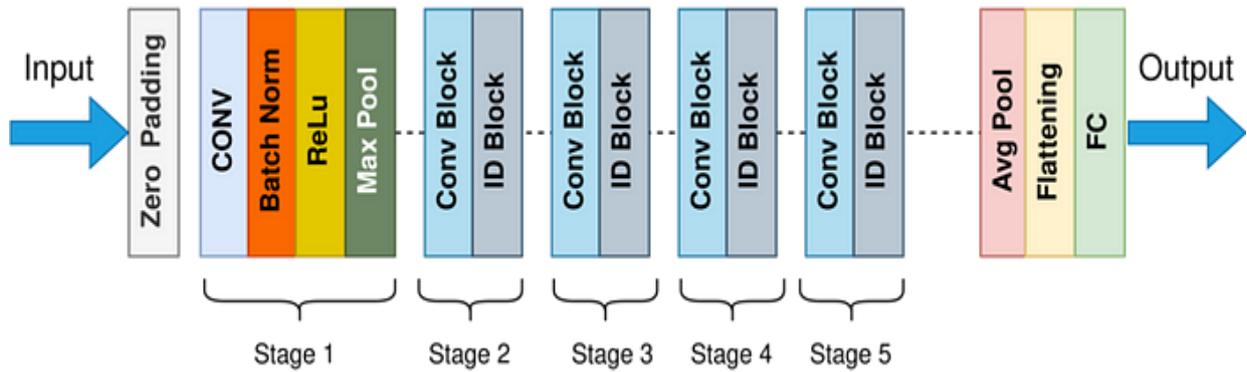


Figure 2.8- Architectures ResNet50

IV.2.3. Architecture DenseNet

DenseNet est un réseau neuronal convolutif qui repose sur des connexions denses entre ses couches. Contrairement à un CNN traditionnel, chaque couche dans DenseNet reçoit l'entrée non seulement de la couche précédente, mais également de toutes les couches qui la suivent dans le même bloc dense. Cette structure en blocs denses est illustrée dans la Figure 2.9, où chaque bloc dense est relié par une couche de transition. Chaque bloc dense contient un ensemble de couches convolutives, et chaque couche est connectée à toutes les autres couches du même bloc. Cette connectivité dense permet un lien direct entre le gradient de la fonction de coût et les entrées originales, favorisant ainsi un flux d'informations plus direct et efficace à travers le réseau. De plus, cette structure contribue à améliorer la régularisation, réduisant ainsi les risques de sur-apprentissage et de dégradation du gradient [29].

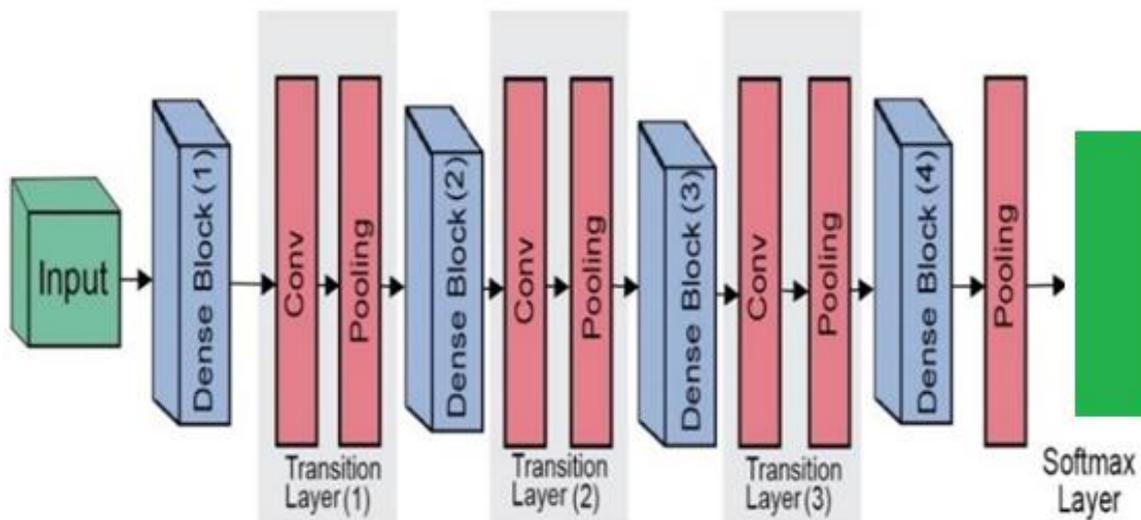


Figure 2.9 - L'architecture DenseNet-121, qui se compose de quatre couches de blocs denses et de trois couches de transition.

DenseNet-121 appartient à la famille des réseaux neuronaux convolutifs et se distingue par sa structure dense. Composé de 121 couches réparties en quatre blocs denses, il favorise une connectivité maximale entre les couches, ce qui facilite l'apprentissage des caractéristiques et la classification. Chaque bloc dense comprend des couches de convolution entrelacées avec des couches de transition pour réduire les dimensions spatiales et le nombre de canaux, contribuant ainsi à une représentation robuste des données en entrée [31].

IV.2.4. Architecture MobileNet

MobileNet est une solution de réseau de neurones convolutionnel conçue pour répondre aux exigences spécifiques des systèmes embarqués. Elle utilise la convolution séparable profonde pour réduire la complexité et les coûts de calcul, et est conçue pour être rapide et léger. MobileNet peut être exécuté efficacement sur des systèmes embarqués avec des ressources limitées et consomme moins d'énergie que les autres architectures CNN, ce qui en fait un choix idéal pour les systèmes embarqués nécessitant une faible consommation d'énergie [32].

L'architecture MobileNet est composée de 28 couches, divisées en deux parties : 13 couches de convolution profonde et 13 couches de convolution ponctuelle. Les couches de convolution profonde appliquent un filtre unique à chaque canal d'entrée, réduisant ainsi la complexité et les coûts de calcul. Les couches de convolution ponctuelle combinent les résultats des couches de convolution profonde [32].

Les optimisations clés de l'architecture MobileNet incluent [32] :

- *Convolution Séparable Profonde* : La convolution profonde est divisée en deux parties : une convolution "profonde" qui applique un filtre unique à chaque canal d'entrée et une convolution "ponctuelle" qui combine les résultats. Cela réduit la complexité et les coûts de calcul.
- *Convolution Légère* : Les convolutions sont légères en termes d'opérations, ce qui permet une exécution rapide et efficace.
- *Réduction de la Complexité* : La complexité de l'architecture est réduite en utilisant des convolutions séparables et des couches de convolution légères, ce qui permet une exécution plus rapide et une consommation d'énergie inférieure.

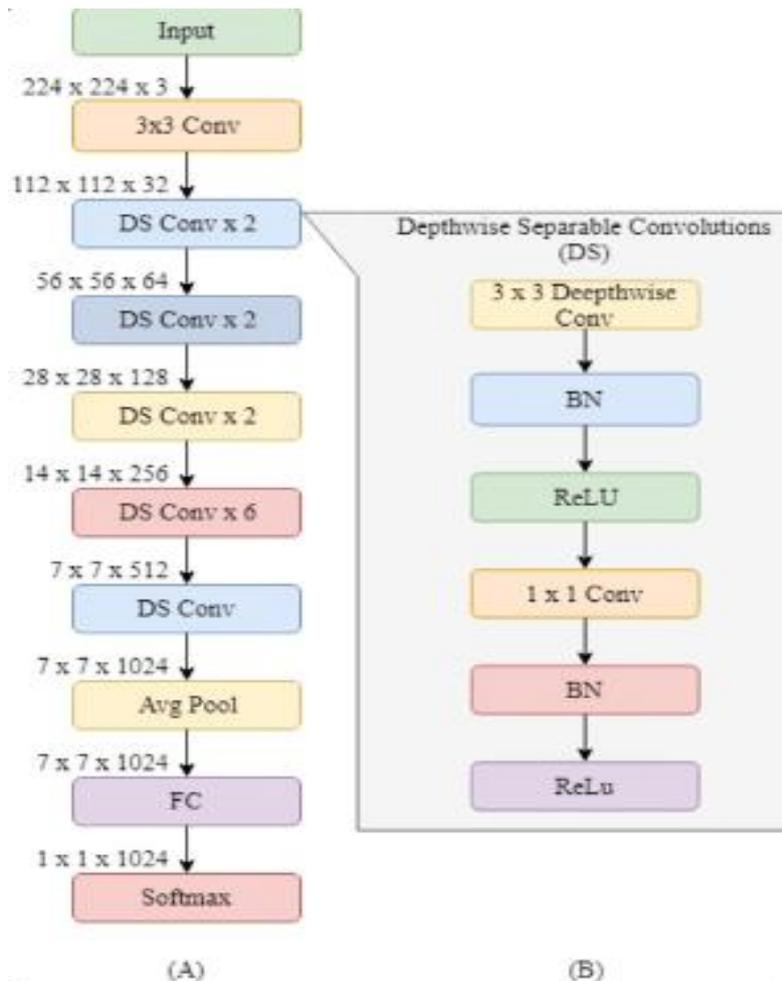


Figure 2.10- Architectures MobileNet

V. Avancées récentes dans la Classification des Affections Cutanées grâce à l'Apprentissage Profond

La littérature récente sur la classification des affections cutanées montre une diversité d'approches, toutes basées sur des techniques sophistiquées d'apprentissage automatique et de réseaux neuronaux profonds. Ces méthodes visent à extraire et analyser les caractéristiques des lésions cutanées pour parvenir à des diagnostics précis et efficaces. Parmi les études significatives, plusieurs ont retenu l'attention par leurs performances remarquables.

Par exemple, Srinivasu et al. [33] ont combiné un réseau neuronal profond avec MobileNet V2 et LSTM, obtenant ainsi un taux de classification de 90.21% sur le jeu de données HAM10000. De leur côté, Shetty et al. [34] ont mis en œuvre une approche hybride associant technique d'apprentissage automatique et CNN, atteignant un taux de classification de 95.18% sur le même ensemble de données. Une performance encore plus impressionnante

a été réalisée par Almuayqil et al. [35], qui ont utilisé DenseNet-201 avec des méthodes d'apprentissage automatique pour obtenir une précision de 99.94% sur HAM10000.

Par ailleurs, Hossain et al. [36] ont proposé une méthode Customized ResNet50, qui a démontré un taux de classification de $84.42\% \pm 1.36$ sur les ensembles de données EM et HAM10000. Dans un autre registre, Ali et al. [37] ont exploré l'efficacité des EfficientNets pour la classification multi-classes du cancer de la peau, obtenant un taux de classification de 87.9% et un F1-score de 87% sur HAM10000.

De manière similaire, Inthiyaz et al. [38] ont utilisé un CNN sur l'ensemble de données Xiangya-Derm, atteignant un taux de classification de 87%. Enfin, Wei et al. [39] ont proposé une approche novatrice basée sur la fusion de DenseNet et ConvNeXt, surpassant les autres modèles avec des taux de classification de 95.29% et 96.54% respectivement sur HAM10000 et un ensemble de données hospitalier (Peking-Union Medical College Hospital).

Ces travaux illustrent la puissance des techniques d'apprentissage profond dans le domaine de la dermatologie, ouvrant la voie à des systèmes de diagnostic plus sophistiqués et précis pour les affections cutanées.

VI. Conclusion

Ce chapitre a offert une introduction approfondie aux concepts de base de l'apprentissage automatique et de l'apprentissage profond, avec une concentration sur leur application dans la classification des images. Nous avons étudié les architectures de réseaux de neurones convolutifs, les algorithmes d'optimisation et les architectures de classification les plus connues. Enfin, nous avons examiné les dernières avancées dans l'utilisation de l'apprentissage profond pour la classification automatique des maladies de peau, ouvrant ainsi la voie à de nouvelles perspectives pour le diagnostic assisté par ordinateur et la prise en charge des patients.

Chapitre 3 - Classification des maladies de la peau : Résultats et discussion

I. Introduction

Le sur-apprentissage et le déséquilibre dans la distribution des données médicales constituent des défis majeurs pour la classification des maladies de la peau. Pour y remédier, il est nécessaire d'ajuster des hyper-paramètres tels que la taille du lot, le taux d'apprentissage et le nombre d'époques, ainsi que l'application de techniques de prétraitement comme l'augmentation des données et l'équilibrage par échantillonnage avec remplacement.

Dans ce chapitre, nous exposons nos contributions pour améliorer la classification et la reconnaissance des maladies de la peau, en abordant spécifiquement le problème de déséquilibre des données. Nous avons divisé notre travail en trois parties :

- *Stratégies de Prétraitement et d'Optimisation pour améliorer la Classification d'Images avec VGG16* : Dans cette partie, nous avons mis en œuvre des stratégies de prétraitement et d'optimisation pour améliorer la classification d'images avec l'architecture VGG16.
- *Analyse Comparative des performances de VGG16, ResNet50, DenseNet121 et MobileNet pour la Classification d'images* : Dans cette partie, nous avons comparé les performances de différents modèles de convolutional neural networks pour la classification d'images, notamment VGG16, ResNet50, DenseNet121 et MobileNet.
- *Analyse comparative entre les performances d'un modèle CNN classique et des modèles pré-entraînés* : Dans cette partie, nous avons comparé les performances d'un modèle CNN classique avec des modèles pré-entraînés pour la classification d'images.
- *Comparaison de nos résultats avec l'état de l'art* : Dans cette partie, nous avons comparé nos résultats avec l'état de l'art dans le domaine de la classification des maladies de la peau. Nous avons implémenté ces étapes en utilisant le langage de programmation Python.

II. Python

Python est un langage de programmation interprété, polyvalent et de haut niveau, utilisé pour le développement web, l'analyse de données, l'automatisation et l'intelligence artificielle. Il contient plusieurs bibliothèques standards, notamment [40] :

1. **TensorFlow** est une bibliothèque open-source de Google pour l'apprentissage automatique et le Deep Learning, utilisée pour des applications telles que la reconnaissance d'image, la compréhension du langage naturel et la prévision de séries temporelles.
2. **Keras** est une bibliothèque open-source de Google pour le machine Learning et le Deep Learning, utilisée pour créer, entraîner et déployer des modèles de réseaux de neurones à grande échelle.

ImageDataGenerator est une classe de la bibliothèque Keras utilisée pour l'augmentation de données en deep learning, permettant de générer des lots d'images avec diverses transformations pour améliorer la performance des modèles et réduire le sur-apprentissage.

3. ***Scikit-learn*** est une bibliothèque open-source de machine Learning pour le langage de programmation Python, utilisée pour l'analyse et la modélisation des données, couvrant des algorithmes de classification, de régression, de clustering et de réduction de dimensionnalité.

III. Outils d'implémentations

Dans ce projet, nous avons utilisé les outils suivants :

1. **Google Colab** : un environnement de développement intégré basé sur le Cloud qui permet d'écrire et d'exécuter du code Python directement dans votre navigateur. Il est particulièrement apprécié pour l'apprentissage automatique, l'analyse de données et l'éducation.
2. **Google Drive** : un service de stockage et de synchronisation de fichiers en ligne qui permet aux utilisateurs de sauvegarder leurs fichiers, photos et documents dans le Cloud, de les accéder depuis n'importe quel appareil connecté à Internet et de les partager facilement avec d'autres utilisateurs.
3. **Kaggle** : une plateforme en ligne reconnue dans le domaine de la science des données et de l'apprentissage automatique qui permet aux data scientists et aux ingénieurs en machine Learning de collaborer, de partager des jeux de données, et de participer à des compétitions pour résoudre divers problèmes de science des données.

Ces outils nous ont permis de développer et de tester notre modèle de Deep Learning pour le diagnostic des maladies de la peau, en utilisant des algorithmes d'apprentissage automatique et des techniques de vision par ordinateur pour analyser des images dermatoscopiques et des données cliniques.

IV. Description des bases de données

Dans ce projet, nous utilisons deux bases de données médicales multi-classes extraites du site Kaggle [41]. Ces bases de données sont couramment utilisées pour la classification et la reconnaissance des maladies de la peau. Voici une description succincte de ces bases :

1) Bases de données ISIC

La base de données ISIC est une collection de 3000 images de maladies cutanées cancéreuses prises au microscope, initiée au niveau international pour améliorer la détection précoce du cancer de la peau grâce à l'intelligence artificielle. Cette base de données contient des images de mélanomes et d'autres types de lésions cutanées, annotées par des experts médicaux. Elle est utilisée pour des compétitions et des recherches en vision par ordinateur afin de développer des algorithmes capables de diagnostiquer le cancer de la peau de manière efficace. Cette base de données contient 9 classes et a un volume de 2 Go. Les classes sont :

1. Kératose actinique
2. Carcinome basocellulaire
3. Dermatofibrome
4. Mélanome
5. Naevus
6. Kératose bénigne pigmentée
7. Kératose séborrhéique
8. Carcinome épidermoïde
9. Lésion vasculaire

Ces bases de données sont cruciales pour l'entraînement et la validation de modèles d'apprentissage profond conçus pour détecter et diagnostiquer automatiquement les maladies de la peau.

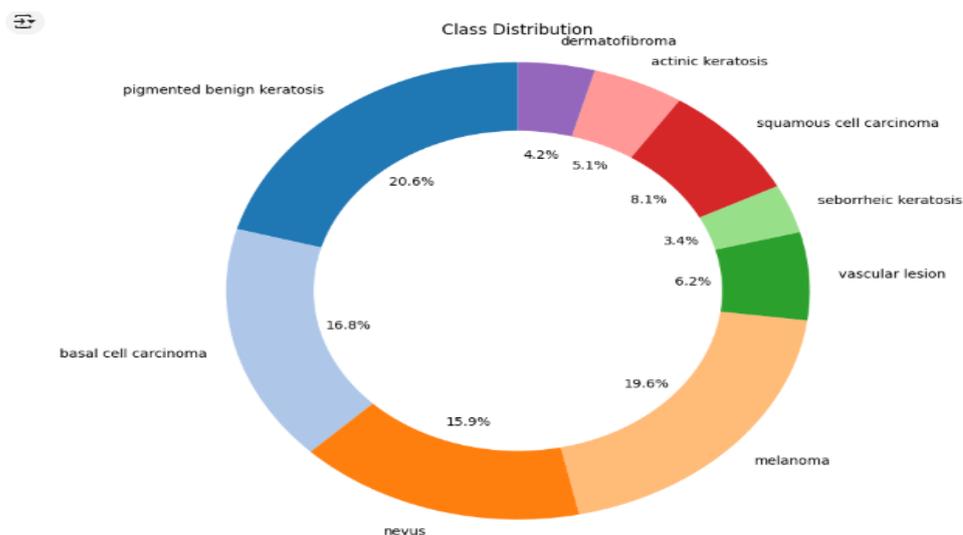


Figure 3.1- Répartition des classes dans la base de données ISIC

Voici quelques images issues de la base d'apprentissage :

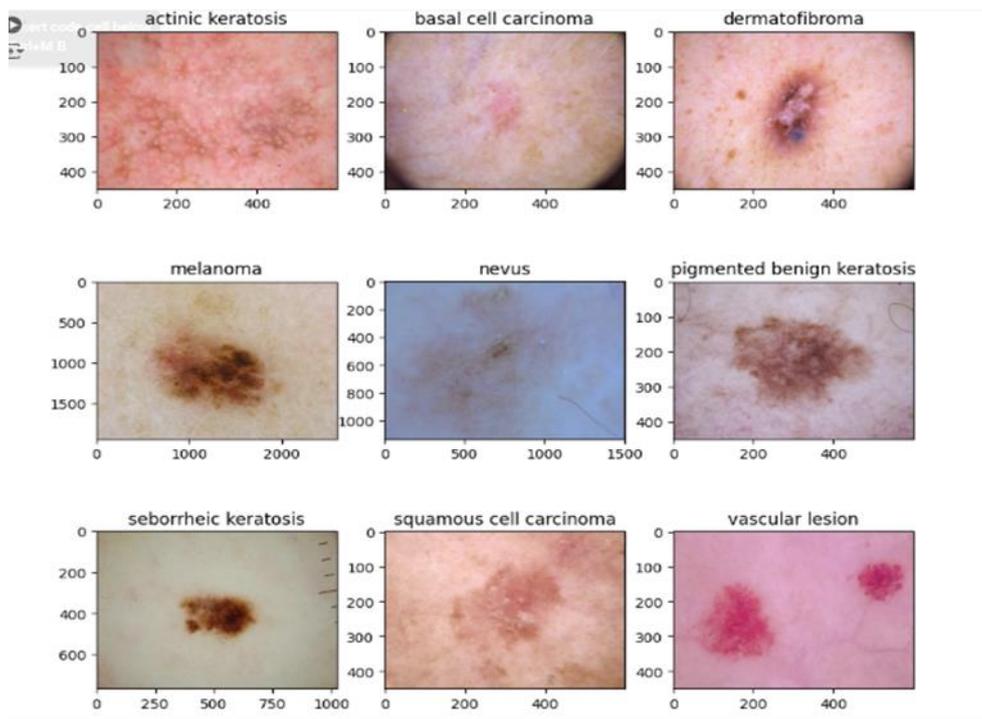


Figure 3.2- Exemples d'images de la base de données ISIC

2) Bases de Données HAM10000

La base de données HAM10000 est une collection de 10000 images de lésions cutanées utilisée pour la recherche en dermatologie et le développement d'algorithmes de détection de maladies de la peau, notamment le cancer de la peau. Cette base de données contient une grande diversité de types de lésions, annotées par des dermatologues experts. Elle est destinée à l'entraînement de modèles d'apprentissage automatique pour la classification des maladies cutanées. Cette base de données contient 7 classes et a un volume de 6 Go. Les classes sont :

- 1- Kératoses actiniques et carcinome intraépithélial / Maladie de Bowen (AKIEC)
- 2- Carcinome basocellulaire (BCC)
- 3- Lésions kératosiques bénignes / Kératoses séborrhéiques et kératoses lichénoïdes (BKL)
- 4- Dermatofibrome (DF)
- 5- Mélanome (MEL)
- 6- Naevi mélanocytaires (NV)
- 7- Lésions vasculaires (angiomes, angiokératomes, granulomes pyogéniques et hémorragies, VASC)

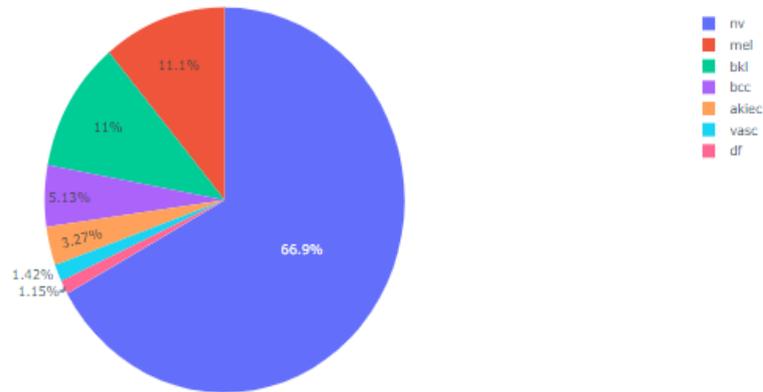


Figure 3.3- Répartition des classes dans la base de données HAM10000

Voici quelques images issues de la base d'apprentissage :

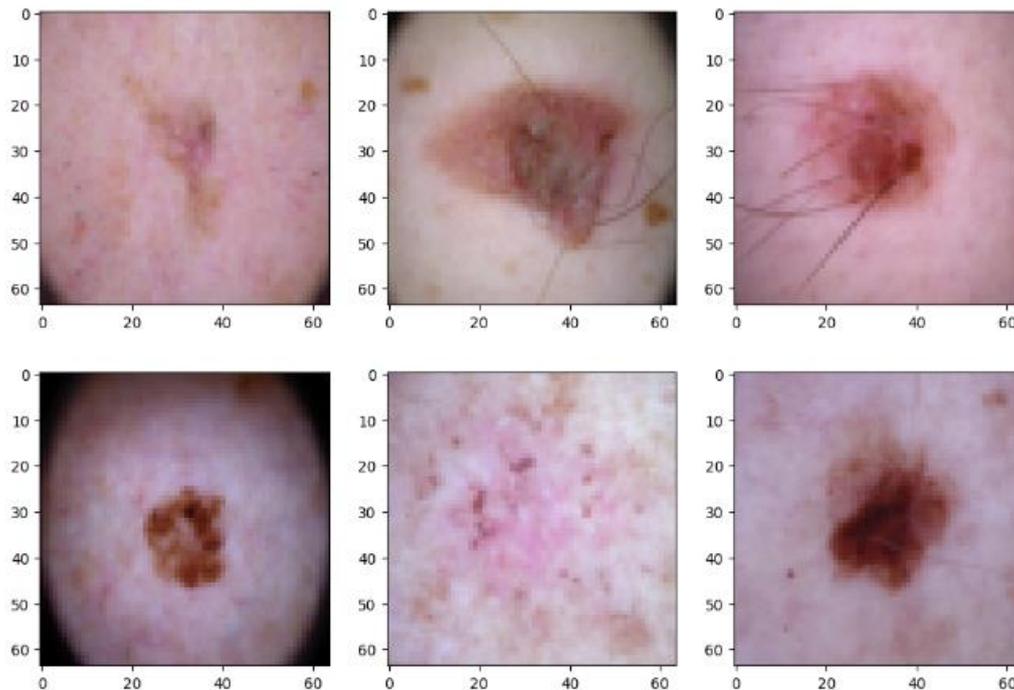


Figure 3.4- Exemples d'images de la base de données HAM10000

V. Application d'un réseau de neurones convolutif classique pour la classification et la reconnaissance des maladies de la peau

Algorithme : Cet algorithme se compose des étapes suivantes :

Étape 1 : Importation des bibliothèques essentielles

- Importer les bibliothèques nécessaires (pandas, numpy, matplotlib, seaborn, etc.)

Étape 2 : Importation des données et création

- Charger les jeux de données (fichiers CSV, bases de données, etc.)
- Créer des structures de données appropriées (dataframes, tenseurs, etc.)

Étape 3 : Analyse exploratoire des données

- Examiner la structure et les caractéristiques des données
- Utiliser des statistiques descriptives et des visualisations pour identifier les tendances et anomalies

Étape 4 : Chargement et redimensionnement des images

- Importer les images
- Ajuster la taille des images pour les rendre compatibles avec les modèles
- Afficher le nombre total d'images disponibles

Étape 5 : Augmentation des données

- Appliquer des techniques d'augmentation des données (rotations, zooms, recadrages, etc.)
- Pour accroître artificiellement la taille du jeu de données

Étape 6 : Séparation des données en ensembles d'entraînement et de test

- Diviser les données en un ensemble d'entraînement et un ensemble de test
- Afficher le nombre total d'images dans chaque ensemble

Étape 7 : Normalisation des données

- Mettre à l'échelle les valeurs des données entre 0 et 1 pour améliorer l'apprentissage

Étape 8 : Architecture du modèle

- Définir la structure d'un modèle de réseau de neurones dense
- Spécifier les couches, les neurones par couche et les fonctions d'activation

Étape 9 : Définition de modèle (CNN classique, etc.)

- Choisir et configurer l'algorithme d'optimisation (Adam, SGD, etc.)
- Pour minimiser la fonction de perte

Étape 10 : Prédiction

- Utiliser le modèle entraîné pour prédire les classes des nouvelles images
 - Évaluer les performances du modèle sur l'ensemble de test
-

VI. Utilisation d'algorithmes de transfert d'apprentissage pour la classification et la reconnaissance des maladies de la peau

Algorithme : Cet algorithme se compose des étapes suivantes :

Étape 1 : Importation des bibliothèques essentielles

- Importer les bibliothèques nécessaires (pandas, numpy, matplotlib, seaborn, etc.)

Étape 2 : Importation des données et création

- Charger les jeux de données (fichiers CSV, bases de données, etc.)
- Créer des structures de données appropriées (dataframes, tenseurs, etc.)

Étape 3 : Analyse exploratoire des données

- Examiner la structure et les caractéristiques des données
- Utiliser des statistiques descriptives et des visualisations pour identifier les tendances et anomalies

Étape 4 : Chargement et redimensionnement des images

- Importer les images
- Ajuster la taille des images pour les rendre compatibles avec les modèles
- Afficher le nombre total d'images disponibles

Étape 5 : Augmentation des données

- Appliquer des techniques d'augmentation des données (rotations, zooms, recadrages, etc.)
- Pour accroître artificiellement la taille du jeu de données

Étape 6 : Séparation des données en ensembles d'entraînement et de test

- Diviser les données en un ensemble d'entraînement et un ensemble de test
- Afficher le nombre total d'images dans chaque ensemble

Étape 7 : Normalisation des données

- Mettre à l'échelle les valeurs des données entre 0 et 1 pour améliorer l'apprentissage

Étape 8 : Architecture du modèle

• **Gel des couches du modèle de base :**

- Toutes les couches du modèle de base sont gelées pour empêcher leur mise à jour pendant l'entraînement ultérieur.

• **Ajout de couches supplémentaires :**

- Création d'un nouveau modèle séquentiel.
 - Ajout du modèle pré-entraîné comme première couche.
 - Insertion d'une couche "Flatten" pour transformer les données en un format adapté aux couches fully connected.
-

- Ajout d'une couche dense avec une activation ReLU pour apprendre des représentations de haut niveau.
- Intégration d'une couche de normalisation par lots pour accélérer la convergence et réduire le sur-ajustement.
- Insertion d'une couche de dropout pour régulariser le modèle et améliorer sa généralisation.
- Ajout d'une couche dense de sortie avec une activation softmax pour prédire les probabilités des classes.

Étape 9 : Définition de modèle (VGG16, ResNet50, DenseNet121 et MobileNet)

- **Compilation du modèle :**

- Compilation du modèle avec l'optimiseur Adam, la fonction de perte de cross-entropy catégorique, et la métrique d'exactitude pour l'évaluation du modèle.

Étape 10 : Prédiction

- Utiliser le modèle entraîné pour prédire les classes des nouvelles images
 - Évaluer les performances du modèle sur l'ensemble de test
-

VII. Critères d'évaluation

Pour évaluer la capacité prédictive des modèles construits, nous utilisons quatre critères d'évaluation, définis comme suit :

1) Taux de classification correcte (Accuracy) : est le rapport entre le nombre de prédictions correctes (vrais positifs + vrais négatifs) et le nombre total d'instances évaluées. Elle donne une idée générale de la performance du modèle.

$$\text{Accuracy} = \frac{(\text{VP} + \text{VN})}{(\text{VP} + \text{VN} + \text{FP} + \text{FN})} \quad (3.1)$$

Où VP est le nombre de vrais positifs, VN est le nombre de vrais négatifs, FP est le nombre de faux positifs et FN est le nombre de faux négatifs.

2) Rappel (Recall), ou sensibilité, mesure la proportion de prédictions positives correctes par rapport au nombre total de véritables cas positifs (vrais positifs + faux négatifs). Il mesure la capacité du modèle à identifier correctement toutes les instances positives.

$$\text{Rappel} = \frac{\text{VP}}{(\text{VP} + \text{FN})} \quad (3.2)$$

3) Précision (Precision) : mesure la proportion de prédictions positives correctes par rapport au nombre total de prédictions positives (vrais positifs + faux positifs). Elle mesure la qualité des prédictions positives du modèle.

$$\text{Précision} = \frac{\text{VP}}{(\text{VP} + \text{FP})} \quad (3.3)$$

4) **F1-Score** : mesure la moyenne harmonique de la précision et du rappel, fournissant une évaluation équilibrée des performances du modèle.

$$F1 - Score = 2 * \frac{(Précision * Rappel)}{(Précision + Rappel)} \quad (3.4)$$

Ces critères d'évaluation permettent de mesurer la performance des modèles de manière exhaustive, en tenant compte à la fois des prédictions correctes et des erreurs, ainsi que de l'équilibre entre les différentes classes.

VIII. Contribution 1 : Stratégies de Prétraitement et d'Optimisation pour améliorer la Classification d'Images avec VGG16

1) Chargement de la base de données d'images ISIC

Nous avons commencé par charger la base de données d'images ISIC, qui contient 3000 images réparties de manière inégale entre 9 classes différentes, ce qui crée un déséquilibre dans la distribution des classes. La figure suivante illustre la répartition des images par classe dans cette base de données.

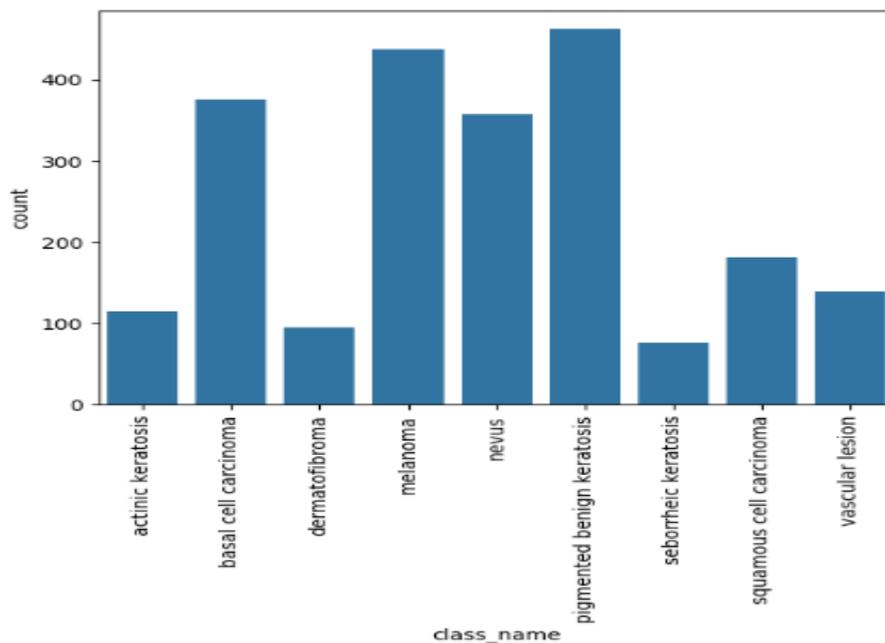


Figure 3.5- Répartition des classes dans la base de données ISIC

Cette base de données a été utilisée comme point de départ pour notre projet, qui vise à développer un modèle capable de diagnostic des maladies de la peau avec une précision élevée.

2) Répartition de la Base de Données

La base de données a été divisée en trois ensembles distincts :

1. Ensemble d'apprentissage : Utilisé pour entraîner le modèle.
2. Ensemble de validation : Utilisé pour ajuster les hyper-paramètres et évaluer le modèle durant l'entraînement.
3. Ensemble de test : Utilisé pour évaluer la performance finale du modèle après l'entraînement.

La figure suivante illustre le processus de division de la base de données d'apprentissage en trois parties:

```
▶ train_ds = tf.keras.preprocessing.image_dataset_from_directory(
    data_dir_train,
    validation_split=0.2,
    subset="training",
    seed=123,
    image_size=(img_height, img_width),
    batch_size=batch_size
)
val_ds = tf.keras.preprocessing.image_dataset_from_directory(
    data_dir_train,
    validation_split=0.2,
    subset="validation",
    seed=123,
    image_size=(img_height, img_width),
    batch_size=batch_size
)
test_ds = tf.keras.preprocessing.image_dataset_from_directory(
    data_dir_test,
    validation_split=0.9,
    subset="validation",
    seed=123,
    image_size=(img_height, img_width),
    batch_size=batch_size
)

⇒ Found 2239 files belonging to 9 classes.
Using 1792 files for training.
Found 2239 files belonging to 9 classes.
Using 447 files for validation.
Found 141 files belonging to 9 classes.
Using 126 files for validation.
```

Figure 3.6- Répartition de la Base de Données

3) Application de VGG16

Le modèle VGG16 pré-entraîné a été appliqué sur la base de données. Ce modèle, reconnu pour sa profondeur et sa capacité à extraire des caractéristiques pertinentes, a servi de point de départ pour notre projet.

4) Réglage des Hyper-paramètres

Nous avons ajusté plusieurs hyper-paramètres critiques :

- Batch-size : La taille des lots d'images traitées ensemble pendant l'entraînement. Dans cette étude, le batch size a été fixé à 32 après plusieurs tests pour optimiser l'entraînement du modèle.
- Taux d'apprentissage : La vitesse à laquelle le modèle met à jour ses poids en réponse aux erreurs observées. Dans cette étude, le taux d'apprentissage a été fixé à 0.0001 après plusieurs tests pour ajuster la vitesse d'apprentissage du modèle.
- Nombre d'époques : Le nombre de passages complets sur l'ensemble de données d'apprentissage. Dans cette étude, le nombre d'époques a été fixé à 25 après plusieurs tests pour déterminer le nombre optimal d'entraînements nécessaires pour atteindre une performance optimale.
- La technique d'optimisation a été choisie comme Adam après plusieurs tests.
- La fonction de perte a été choisie comme Categorical Crossentropy après plusieurs tests.

Ces ajustements ont été effectués pour optimiser les performances du modèle et améliorer sa capacité à généraliser.

5) Détection de l'Overfitting

La figure ci-dessous illustre les résultats du taux de classification (Accuracy) et de la perte (Loss) obtenus lors de l'entraînement et de la validation avant l'application de l'augmentation et de l'équilibrage des données.

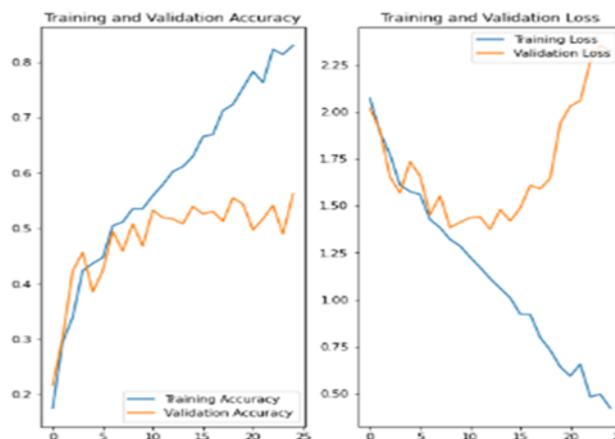


Figure 3.7 – Résultats obtenus avant l'augmentation et l'équilibrage des données

Lors de l'entraînement initial, un sur-apprentissage (*overfitting*) a été constaté, où le modèle performait bien sur l'ensemble d'apprentissage mais échouait à généraliser sur l'ensemble de validation. Cette différence de performance entre les données d'entraînement et de validation était d'environ 20%.

La précision d'entraînement se situait autour de 70-75% après 25 époques, indiquant que le modèle n'avait pas encore appris de nombreuses caractéristiques importantes.

De plus, un déséquilibre important dans la distribution des données a été observé. Ce déséquilibre des données peut entraîner un biais dans le modèle, faussant ainsi les résultats et les prédictions.

En raison de cet important déséquilibre, les résultats et les prédictions du modèle seront biaisés et ne refléteront pas fidèlement les performances réelles du modèle sur des données équilibrées.

6) Application de la Technique d'Augmentation

Pour surmonter le problème d'*overfitting*, nous avons appliqué des techniques d'augmentation de données (Prétraitement). Cela comprenait des transformations telles que :

- Application de Zoom aléatoire sur les images
- Rotation et translation des images.
- Application de flips horizontaux/verticaux.

Pour améliorer la performance de notre modèle, nous avons augmenté le nombre d'images dans chaque classe à 1000, ce qui a permis d'équilibrer le jeu de données et de réduire le déséquilibre entre les classes.

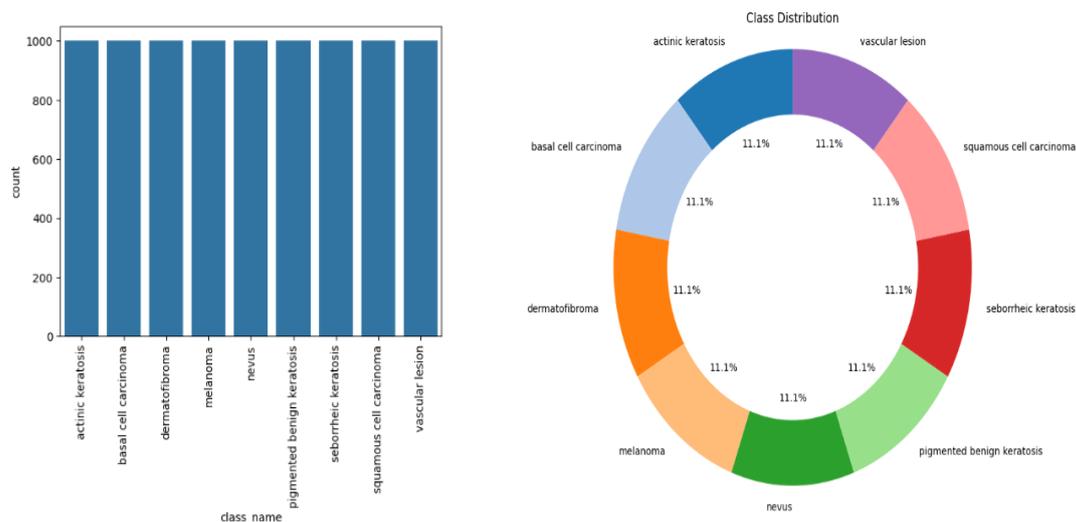


Figure 3.8 - Répartition des classes dans la base de données après augmentation et équilibrage des données

La figure 3.8 illustre la distribution équilibrée des 9 classes dans la base de données après l'application de techniques d'augmentation des données. Chaque classe contient désormais approximativement le même nombre d'images, soit environ 1000 images par classe. Cet équilibrage permet de réduire le biais potentiel du modèle dû à un déséquilibre initial des données.

7) Ré-application de VGG16

Après l'augmentation des données, le modèle VGG16 a été ré-entraîné. Cette fois, il a montré une meilleure généralisation et des performances améliorées sur l'ensemble de validation. La figure suivante illustre les résultats obtenus après l'augmentation et l'équilibrage des données :

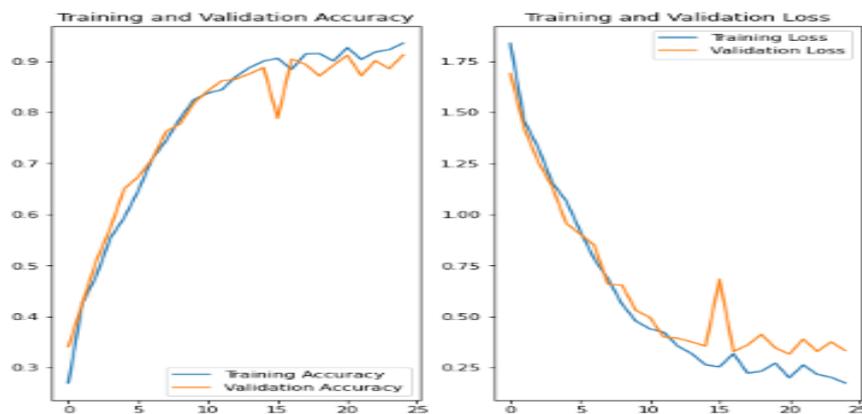


Figure 3.9 – Résultats obtenus après l'augmentation et l'équilibrage des données

L'application de techniques d'augmentation des données et d'ajustement des hyper-paramètres a permis au modèle VGG16 de surmonter efficacement le problème de sur-apprentissage (overfitting) et d'atteindre des performances robustes sur l'ensemble de validation.

En rééquilibrant et en ré-échantillonnant les données pour obtenir une représentation équitable de chaque classe, la précision du modèle a été significativement améliorée, atteignant 90%. Cela a résolu le problème initial de faible précision.

Le sur-apprentissage a été maîtrisé, réduisant l'écart de performances entre les ensembles d'entraînement et de validation à seulement 4-5%. Ces résultats indiquent que le modèle optimisé, avec des données rééquilibrées, constitue la meilleure configuration possible.

Cette contribution démontre une mise en œuvre rigoureuse et systématique des techniques d'apprentissage profond pour relever un défi complexe, en surmontant avec succès les obstacles posés par le sur-apprentissage et le déséquilibre des données.

IX. Contribution 2 : Analyse Comparative des performances de VGG16, ResNet50, DenseNet121 et MobileNet pour la Classification d'images

Dans cette étape, nous avons mené une étude comparative des performances obtenues après avoir appliqué VGG16, ResNet50, DenseNet121 et MobileNet sur la base de données prétraitée dans la section précédente.

La figure suivante illustre les résultats obtenus par le modèle ResNet50:

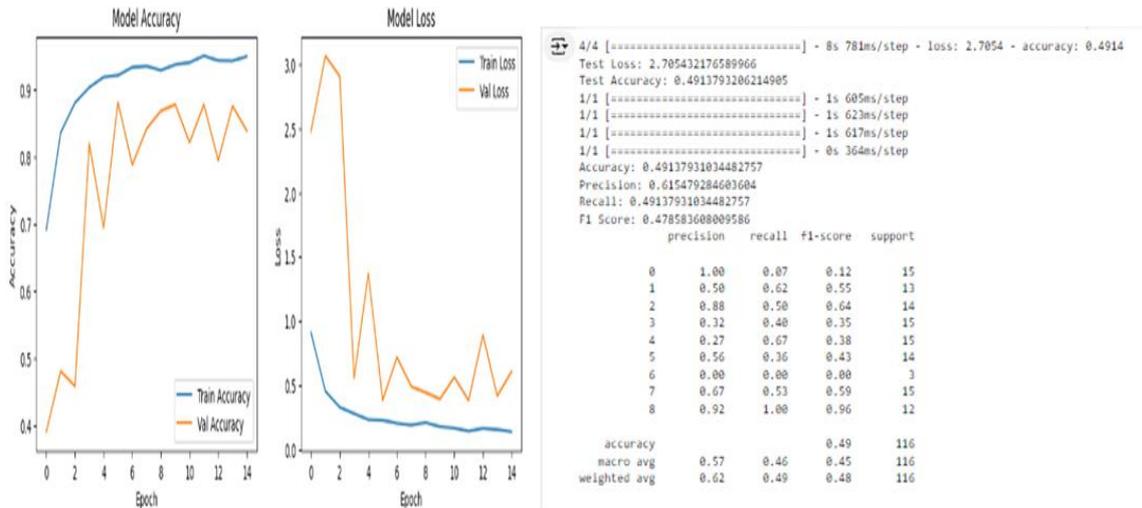


Figure 3.10 –Performance du modèle ResNet50 après augmentation et équilibrage des données

Après 14 époques d'entraînement, le modèle ResNet50 a montré une meilleure généralisation et des performances améliorées sur l'ensemble de validation. Bien que ces résultats soient encourageants, quelques défis persistent. Le modèle parvient à correctement identifier plus de la moitié des exemples positifs avec une précision de 61,5%, mais son rappel de 49% suggère une sensibilité limitée dans la détection des vrais positifs. Un F1-score de 47,8% souligne la nécessité d'améliorer globalement les performances, en tenant compte à la fois de la précision et du rappel. Le taux de classification de 49% indique que le modèle a correctement classé environ la moitié des exemples du jeu de données de test.

Note : Les résultats mentionnés ont été obtenus après un temps total d'entraînement de 5 heures en utilisant Google Colab.

La figure suivante illustre les résultats obtenus par le modèle Mobilenet :

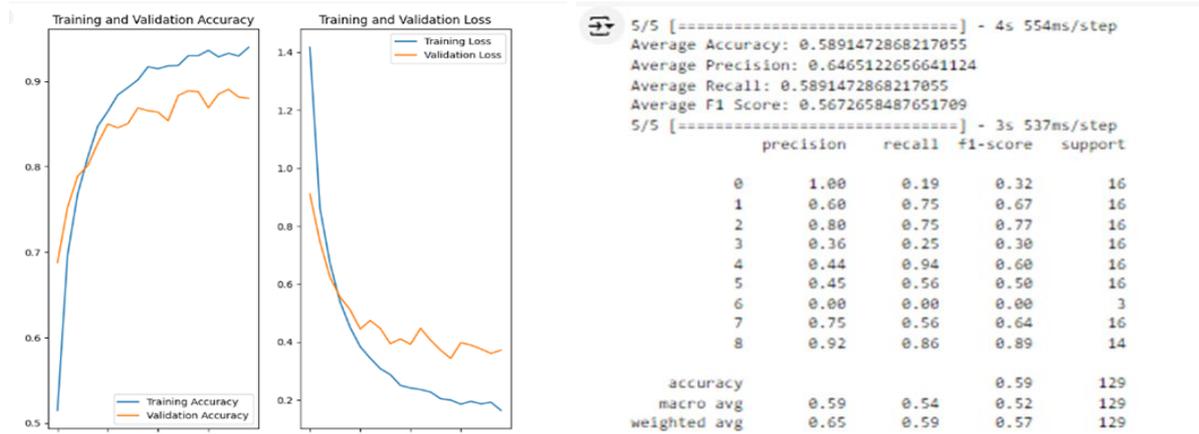


Figure 3.11 –Performance du modèle MobileNet après augmentation et équilibrage des données

Les résultats du modèle MobileNet après 15 époques d'entraînement montrent une performance prometteuse. Le modèle atteint un taux de classification de 58,9%, une précision de 64,6%, un rappel de 58,9% et un F1-score de 56,7%. Ces chiffres indiquent une bonne capacité du modèle à généraliser et à équilibrer précision et rappel.

Le temps d'entraînement a été de 2,5 heures sur Google Colab, ce qui est efficace. Ces résultats suggèrent que MobileNet est performant pour la classification d'images, mais qu'il existe encore des possibilités d'amélioration.

La figure suivante illustre les résultats obtenus par le modèle DenseNet-121:

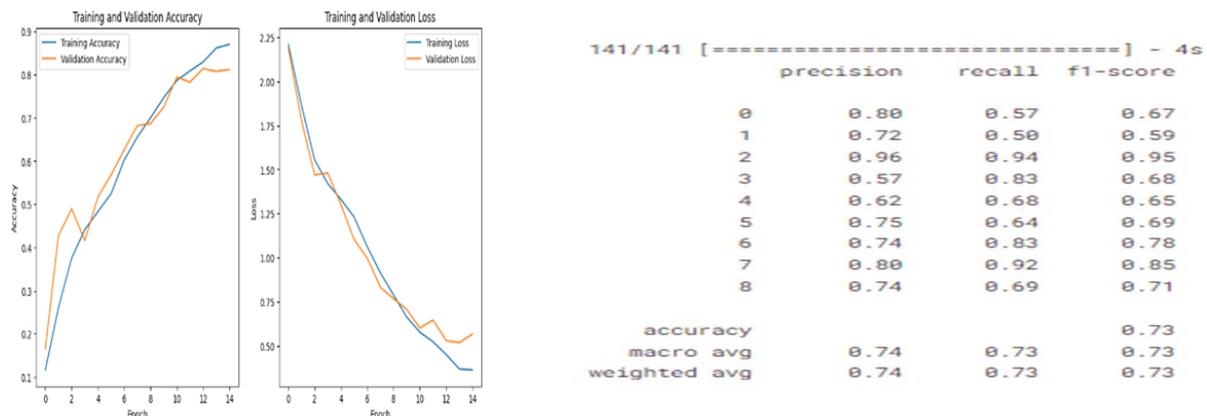


Figure 3.12–Performance du modèle DenseNet-121 après augmentation et équilibrage des données

Après 14 époques d'entraînement, le modèle DenseNet-121 a montré une amélioration significative de ses performances sur l'ensemble de validation. Il a atteint un taux de classification de 73%, une précision de 74%, un rappel de 73% et un F1-score de 73%. L'entraînement, effectué en 5 heures sur Google Colab, a démontré une efficacité notable. Ces

résultats suggèrent que DenseNet-121 est efficace pour la classification d'images, bien que des améliorations soient encore possibles.

La figure suivante illustre les résultats obtenus par le modèle VGG16 :

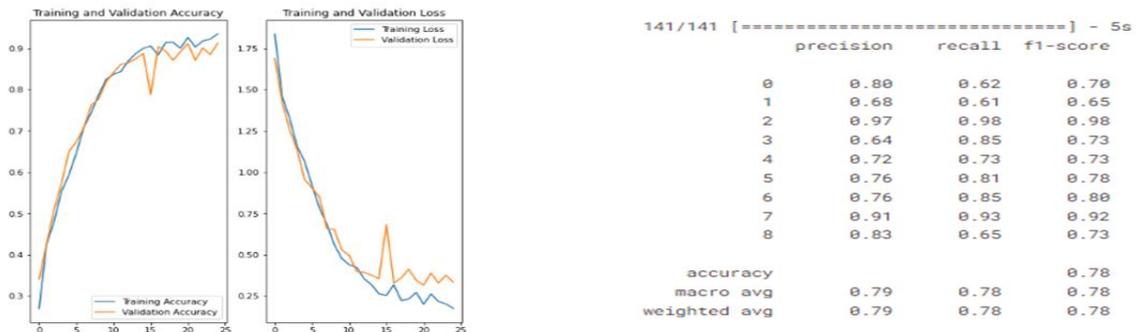


Figure 3.13—Performance du modèle VGG16 après augmentation et équilibrage des données

Après 20 époques d'entraînement, les résultats du modèle VGG16 montrent des performances prometteuses. Le modèle atteint un taux de classification de 78%, avec une précision de 79%, un rappel de 77%, et un F1-score de 78%. Ces chiffres indiquent que le modèle VGG16 est capable d'identifier correctement une grande majorité des exemples et qu'il équilibre bien la précision et le rappel.

Le temps d'entraînement de 6,5 heures sur Google Colab est raisonnable, compte tenu de la complexité du modèle et de la taille des données. Cependant, bien que les résultats soient solides, il existe toujours des possibilités d'amélioration, notamment en explorant des techniques de régularisation supplémentaires, des ajustements d'hyper-paramètres pour atteindre une performance encore meilleure.

Les résultats obtenus à partir des différents modèles d'apprentissage profond pour la classification d'images de maladies de la peau montrent des performances variées. Parmi les modèles testés :

- *VGG16* a montré des performances prometteuses avec un taux de classification de 78%, une précision de 79%, un rappel de 77%, et un F1-score de 78% après 20 époques d'entraînement.
- DenseNet-121 a atteint un taux de classification de 73% après 14 époques, démontrant une bonne efficacité.
- MobileNet, après 14 époques, a obtenu un taux de classification de 59%, montrant une bonne généralisation mais laissant place à l'amélioration.

- ResNet50 a obtenu un taux de classification de 61.5%, un rappel de 49%, et un F1 score de 47.8% après 20 époques d'entraînement. Ces résultats montrent des aspects encourageants mais également des défis à relever, notamment en termes de sensibilité et de performance globale.

Les résultats obtenus montrent l'importance de choisir et d'optimiser le bon modèle pour maximiser les performances. Le déséquilibre des classes dans la base de données a été une considération importante tout au long du projet. Des techniques supplémentaires telles que l'échantillonnage des données pourraient être explorées pour améliorer davantage la performance du modèle. Il reste des opportunités pour affiner les modèles actuels et explorer de nouvelles approches pour améliorer la classification d'images de maladies de la peau.

X. Contribution 3 : Analyse comparative entre les performances d'un modèle CNN classique et des modèles pré-entraînés

Cette étape examine l'efficacité du modèle CNN classique et des modèles pré-entraînés sur une base de données déséquilibrée prétraitées par la technique de sur-échantillonnage.

Cette étape décrit le contexte de l'expérience, mettant en évidence le changement de base de données pour évaluer les modèles dans des conditions plus réalistes et exigeantes.

1) Chargement de la Base de Données HAM10000

Nous avons commencé par charger la base de données d'images HAM10000, composée de 10000 images réparties de manière inégale entre 7 classes différentes, ce qui entraîne un déséquilibre significatif dans la distribution des classes. La figure suivante illustre la répartition des images par classe dans cette base de données.

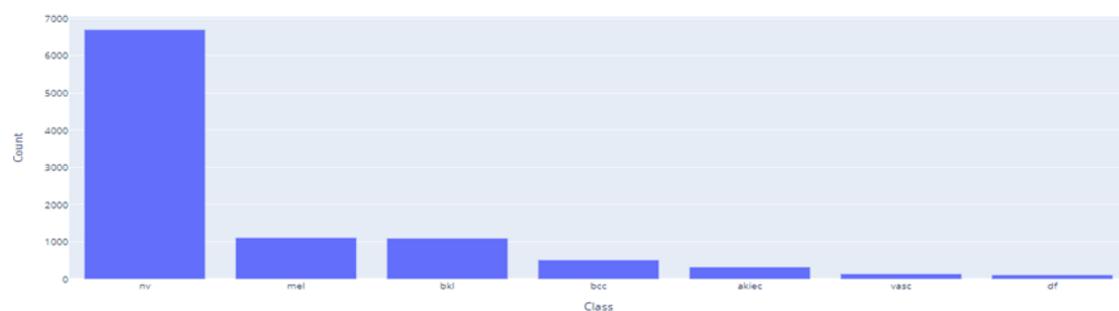


Figure 3.14 - Répartition des classes dans la base de données HAM10000

2) Application de la technique de ré-échantillonnage

L'échantillonnage est une méthode essentielle en science des données pour ajuster la distribution des classes dans un ensemble de données. Dans le cadre de notre projet, nous

avons utilisé la technique d'échantillonnage avec remplacement (Resample) pour surmonter le problème de déséquilibre des données. Nous avons fixé le nombre d'échantillons souhaités pour chaque classe après ré-échantillonnage à 1500.

Le principe de cette technique est le suivant :

- Utiliser les données existantes et sélectionner des échantillons, éventuellement avec remplacement.

- Si une classe compte moins d'échantillons que le nombre souhaité, certaines observations sont répétées.

- Ne générer pas de nouvelles observations, seulement des copies des existantes.

Les méthodes de sur-échantillonnage sont essentielles pour garantir une représentation équitable de toutes les classes lors de l'entraînement des modèles.

3) Analyse comparative entre les performances d'un modèle CNN classique et des modèles pré-entraînés

L'étape suivante examine l'efficacité du modèle CNN classique et des modèles pré-entraînés dans des scénarios réels, en prenant en compte les défis liés au déséquilibre des données.

a. Réglage des Hyper-paramètres

Nous avons ajusté plusieurs hyper-paramètres critiques pour optimiser l'entraînement du modèle :

- Le batch-size a été fixé à 32 après plusieurs tests pour optimiser l'entraînement du modèle.

- Le taux d'apprentissage a été fixé à 0.0001 après plusieurs tests pour ajuster la vitesse d'apprentissage du modèle.

- Le nombre d'époques a été fixé à 100 après plusieurs tests pour déterminer le nombre optimal d'entraînements nécessaires pour atteindre une performance optimale.

- La technique d'optimisation a été choisie comme Adam après plusieurs tests.

- La fonction de perte a été choisie comme Categorical Crossentropy après plusieurs tests.

Ces ajustements ont été effectués pour optimiser les performances du modèle et améliorer sa capacité à généraliser.

b. Description du modèle CNN classique

Le modèle CNN classique est composé de plusieurs couches qui travaillent ensemble pour extraire les caractéristiques des images, réduire leur dimensionnalité et effectuer la classification finale. Les principales couches sont :

- Les couches convolutives qui appliquent des filtres pour extraire les caractéristiques locales des images
- Les couches de pooling qui réduisent la dimensionnalité des cartes d'activation
- Les couches entièrement connectées qui effectuent la classification finale basée sur les caractéristiques extraites

Pour améliorer l'apprentissage, le modèle utilise :

- La normalisation par lots pour accélérer la convergence
- Des activations non linéaires comme ReLU
- Le dropout pour la régularisation et éviter le surapprentissage

La couche de sortie applique la fonction Softmax pour calculer les probabilités normalisées de chaque classe, permettant des prédictions précises.

En combinant ces différentes couches et techniques, le modèle CNN classique est capable d'apprendre efficacement les représentations visuelles pertinentes pour la classification d'images, en faisant de lui une architecture de référence dans le domaine de la vision par ordinateur. Le tableau ci-dessous détaille les principales caractéristiques du modèle CNN classique :

<i>Type de couche</i>	<i>Fonction</i>	<i>Taille</i>	<i>Nombre de Filtres</i>	<i>Taille du Filtre</i>	<i>Padding</i>	<i>Activation</i>
Convolution	Conv2D	64x64x32	32	3x3	Same	ReLU
Max pooling	MaxPooling2D	32x32x32	32	2x2	valid	-
Normalisation par lots	BatchNormalization	32x32x32	32	-	-	-
Convolution	Conv2D	32x32x64	64	-	Same	ReLU
Convolution	Conv2D	32x32x64	64	-	Same	ReLU
Max pooling	MaxPooling2D	16x16x64	64	2x2	valid	-
Normalisation par lots	BatchNormalization	16x16x64	64	-	-	-
Convolution	Conv2D	16x16x128	128	-	Same	ReLU
Convolution	Conv2D	16x16x128	128	-	Same	ReLU
Max pooling	MaxPooling2D	8x8x128	128	2x2	Same	-
Normalisation par lots	BatchNormalization	8x8x128	128	-	-	-
Flatten	Flatten	8192	-	-	-	-
Dropout	Dropout	8192	-	-	-	-

Dense	Dense	256	-	-	-	ReLU
Dropout	Dropout	256	-	-	-	-
dense_2	Dense	128	-	-	-	ReLU
Dropout	Dropout	128	-	-	-	-
dense_3	Dense	32	-	-	-	ReLU
Normalisation par lots	BatchNormalization	32	-	-	-	-
classifieur	Dense	7	-	-	-	softmax

Tableau 3.1 - Description du Modèle CNN classique

c. Résultats et discussions

Les figures suivantes illustrent les résultats obtenus par le modèle CNN classique:

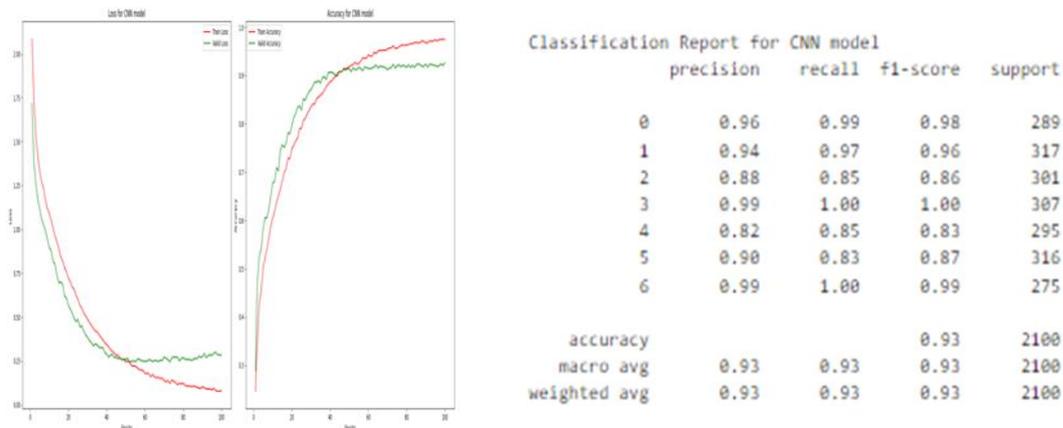


Figure 3.15 –Performance du modèle CNN classique après l'équilibrage des données

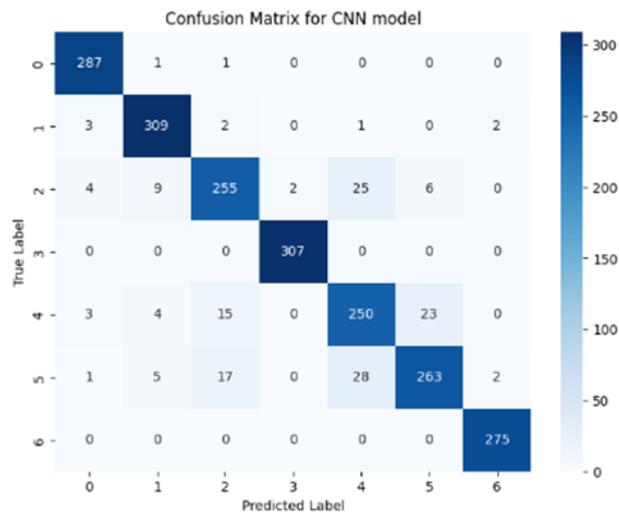


Figure 3.16 – Matrice de confusion du modèle CNN classique

Le modèle CNN classique a enregistré une amélioration notable de ses performances, atteignant un taux de classification de 93%, une précision de 92,8%, un rappel de 92,8%, et un score F1 évalué à 92,8%. Ces résultats soulignent la robustesse et l'efficacité du modèle CNN classique pour la classification des images de maladies de la peau.

La matrice de confusion confirme ces observations, avec des valeurs élevées sur la diagonale principale indiquant une bonne capacité du modèle à identifier correctement les différentes classes.

Ces résultats sont très encourageants et démontrent le potentiel du modèle CNN classique pour le diagnostic assisté par ordinateur des affections cutanées. Ils ouvrent la voie à des applications pratiques dans le domaine médical, en complément des expertises des dermatologues.

Les figures suivantes illustrent les résultats obtenus par le modèle ResNet50:

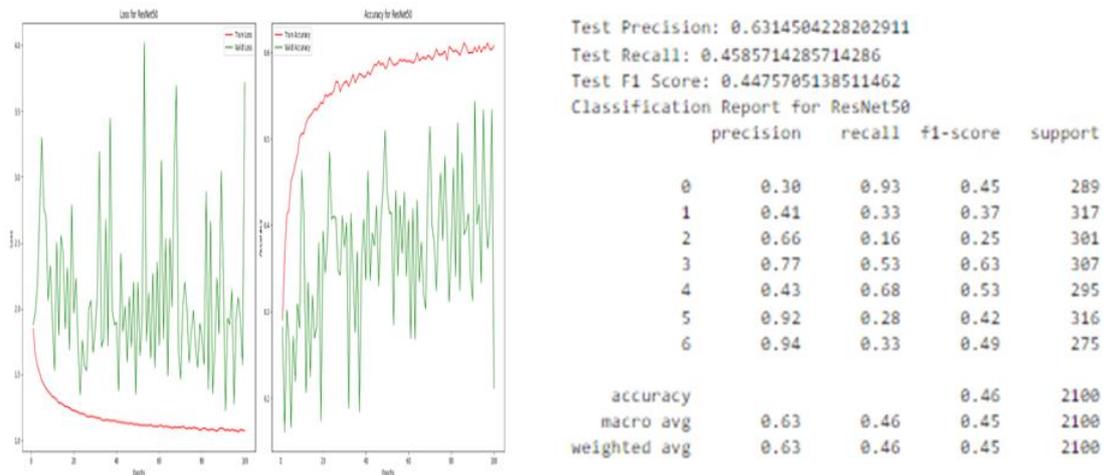


Figure 3.17—Performance du modèle ResNet50 après l'équilibrage des données

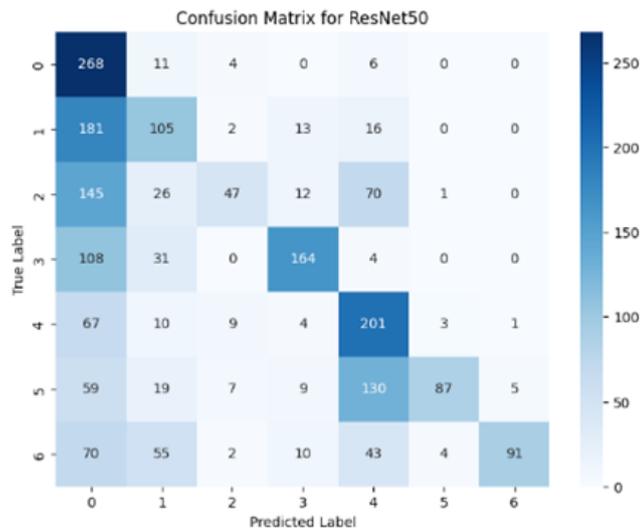


Figure 3.18— Matrice de confusion du modèle ResNet50

Les résultats du modèle ResNet50 après échantillonnage montrent une performance mitigée. Le modèle a atteint un taux de classification de 46%, une précision de 63,14%, un rappel de 45,86%, et un F1-score de 44,76%. Ces chiffres révèlent une instabilité des valeurs de validation, entraînant une faible précision globale. Bien que le modèle puisse correctement

prédire une partie des exemples positifs, il en manque presque la moitié, ce qui réduit sa fiabilité, comme clairement indiqué dans la matrice de confusion. Pour améliorer ces résultats, des ajustements des hyper-paramètres, une augmentation des données ou l'utilisation de techniques de régularisation supplémentaires pourraient être nécessaires.

Les figures suivantes illustrent les résultats obtenus par le modèle DenseNet-121:

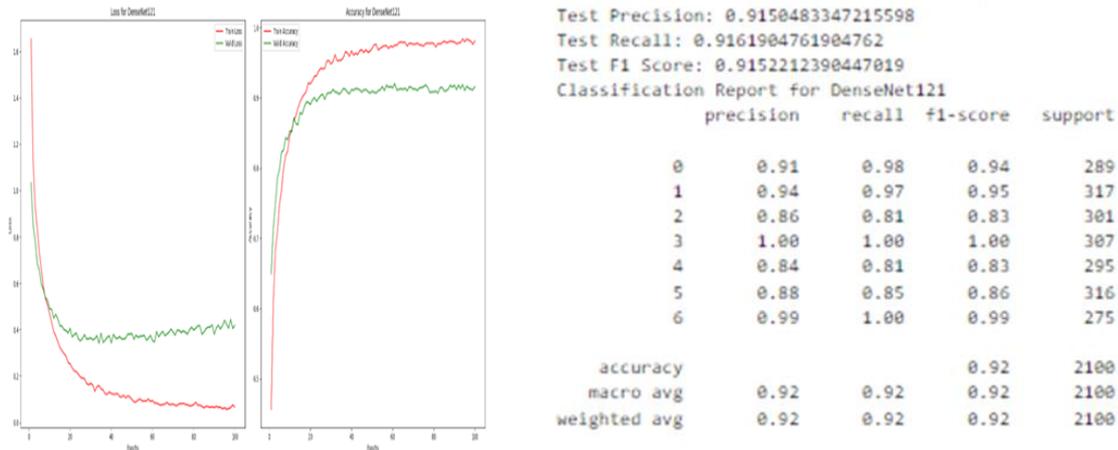


Figure 3.19 – Performance du modèle DenseNet-121 après l'équilibrage des données

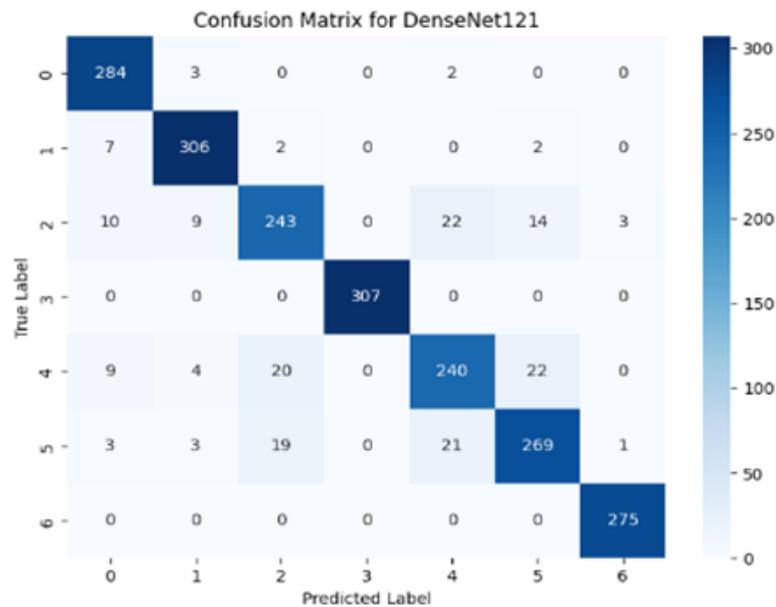


Figure 3.20– Matrice de confusion du modèle DenseNet-121

Après les modifications apportées à la base de données, les performances du modèle DenseNet-121 ont nettement surpassé celles de ResNet50. Avec une précision, un rappel et un F1-score tous évalués à 91.5%, DenseNet-121 a démontré une capacité supérieure à identifier correctement les exemples positifs et négatifs. Ces résultats suggèrent que DenseNet-121 est plus fiable et robuste pour la classification d'images de maladies de la peau que ResNet50, ce

qui pourrait avoir un impact significatif sur la précision des diagnostics assistés par ordinateur.

Les figures suivantes illustrent les résultats obtenus par le modèle MobileNet:

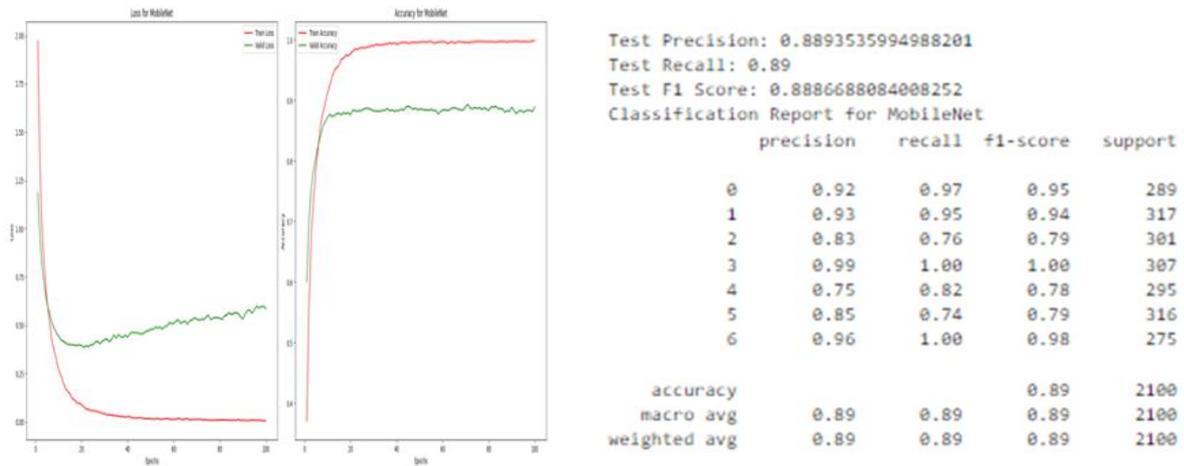


Figure 3.21—Performance du modèle MobileNet après l'équilibrage des données

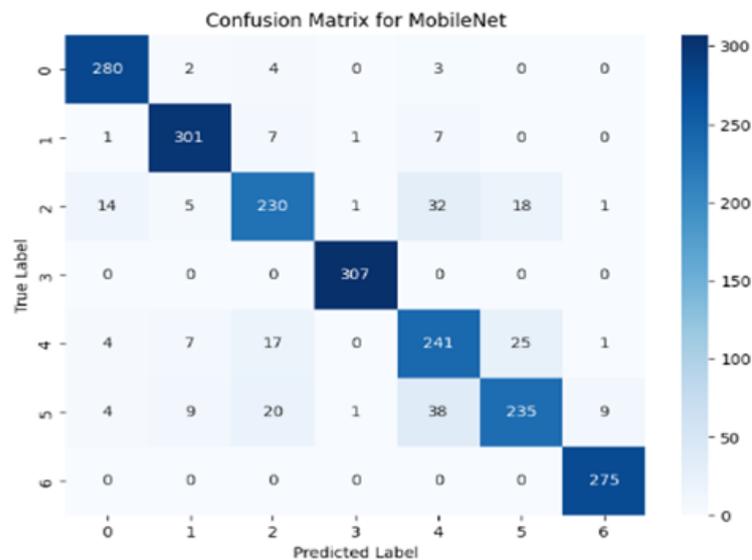


Figure 3.22— Matrice de confusion du modèle MobileNet

Après les modifications apportées à la base de données, les performances du modèle MobileNet ont montré une amélioration notable. Avec une précision, un rappel et un F1-score tous évalués à 88,9%, MobileNet a démontré une capacité accrue à identifier correctement les exemples positifs et négatifs. Bien que ces performances ne rivalisent pas avec celles de DenseNet, la précision de 89% pour les tests reste considérablement élevée et acceptable.

Les figures suivantes illustrent les résultats obtenus par le modèle VGG16:

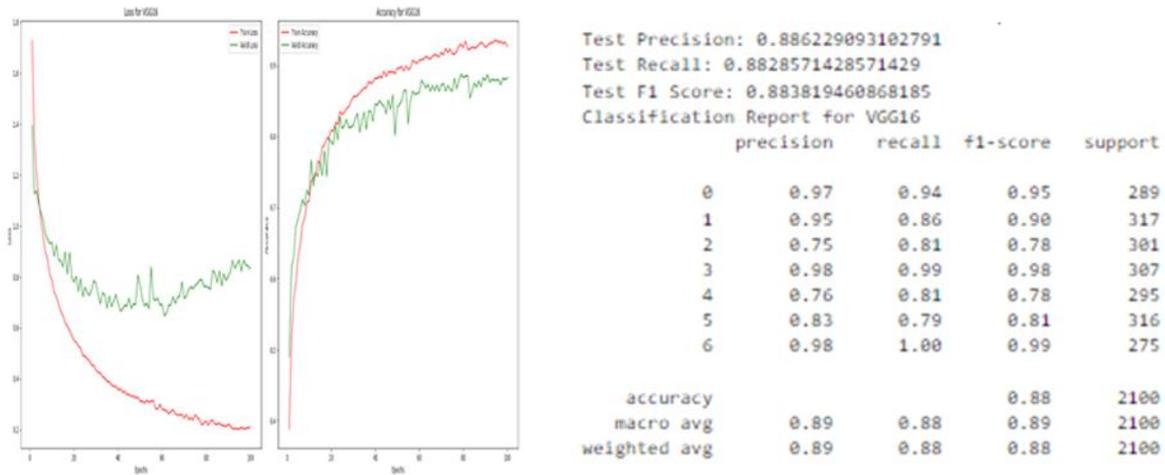


Figure 3.23–Performance du modèle VGG16 après équilibrage des données

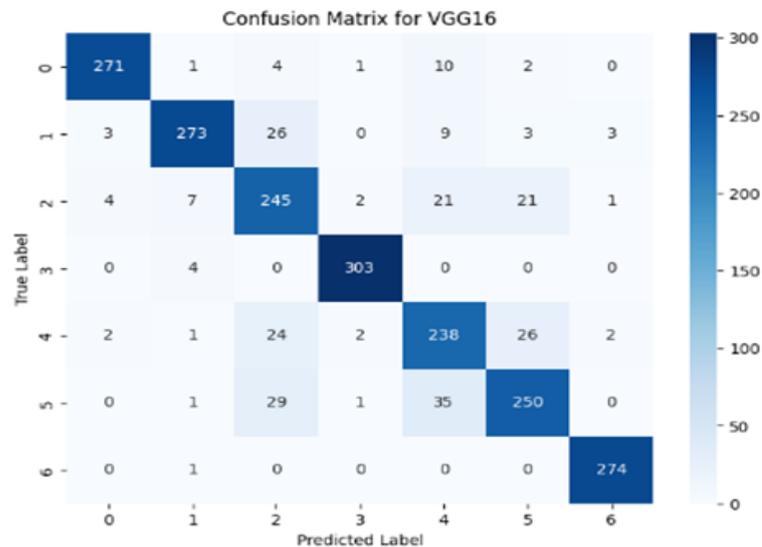


Figure 3.24– Matrice de confusion du modèle VGG16

VGG16 a également démontré une amélioration significative, atteignant une précision de 88,6%, un rappel de 88,2%, et un score F1 évalué à 88%. Ces résultats confirment l'efficacité de VGG16 après les ajustements apportés à la base de données, le positionnant comme un autre modèle performant pour la classification d'images de maladies de la peau.

d. Évaluation des Prédictions sur la Base de Test

Nous avons effectué des prédictions sur quelques exemples de la base de test en chargeant des images et en les évaluant. Dans l'ensemble, la plupart des résultats étaient précis, mais certaines images ont été mal classées. Nous sommes en train de corriger ces erreurs dans nos futures itérations pour améliorer la précision et la robustesse de notre modèle de classification d'images de maladies de la peau.

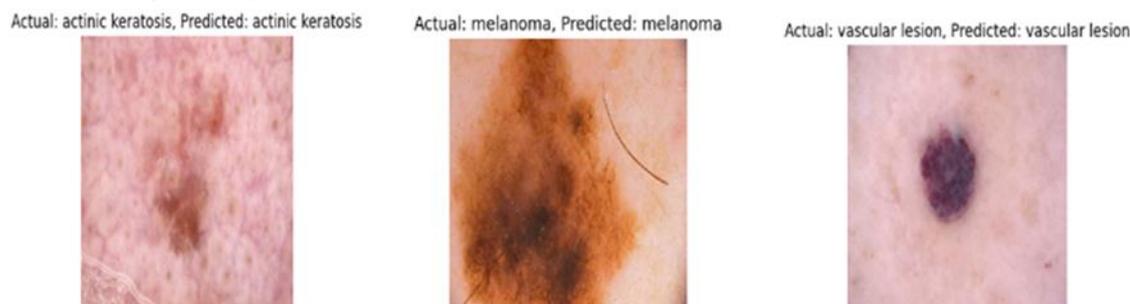


Figure 3.25– Résultats de prédiction pour la base de données ISIC



Figure 3.26– Résultat de prédiction pour la base de données HAM10000

Dans le développement de modèles de détection des maladies de la peau, des ajustements ont été apportés pour améliorer la convergence, notamment en optimisant la taille du lot et le taux d'apprentissage. L'évaluation de différentes architectures, notamment le CNN classique, DenseNet-121, VGG16, MobileNet et ResNet, a montré que le CNN classique a obtenu la meilleure précision à 92,8%, suivi de près par DenseNet-121 à 92%. Les modèles moins profonds ont montré une meilleure précision et une convergence plus stable, tandis que les réseaux neuronaux convolutifs classiques ont surpassé les modèles pré-entraînés en performances, bien que le transfert d'apprentissage offre également des résultats satisfaisants.

XI. Comparaison de nos résultats avec l'état de l'art

Le tableau suivant présente le taux de classification et F1-score obtenus par CNN Classique, DenseNet-121 et d'autres méthodes appliquées sur l'ensemble de données HAM10000.

<i>Méthodes</i>	Taux de classification	F1-score
RegNetY-320 [42]	91%	88.1%
Self-Transfer GAN (STGAN) [43]	98,23%	89,48%
DenseNet-121	92%	91.5%
CNN classique	92.8%	92.8%

Tableau 3. 2- Taux de classification et F1-score obtenus

Une étude récente a proposé une méthode d'apprentissage profond basée sur l'architecture RegNetY-320 pour la classification automatique des cancers de la peau. Cette approche a atteint des performances élevées, avec un taux de classification de 91% et un score F1 de 88.1% [42]. Une autre étude a proposé une méthode à deux étapes basée sur les GAN pour synthétiser des images de lésions cutanées de haute résolution et diverses de 256×256 pixels pour le jeu de données déséquilibré, nommé Self-Transfer GAN (STGAN). Pour la classification, cette approche a atteint des résultats remarquables, avec un taux de classification de 98,23% et un score F1 de 89,48% [43].

Nos propres travaux ont utilisé des techniques d'ajustement des hyper-paramètres, de prétraitement et d'équilibrage des données d'entraînement pour améliorer les performances des modèles de classification des cancers cutanés. Les résultats obtenus après ces améliorations sont très encourageants et se positionnent favorablement par rapport à l'état de l'art actuel sur la classification automatique des lésions cutanées.

XII. Conclusion

Les résultats de l'évaluation des différents modèles de convolutional neural network sur notre ensemble de données de classification d'images ont été très encourageants. Bien que les performances varient en fonction des architectures de modèles, nous avons observé des améliorations significatives après des ajustements appropriés et des techniques de prétraitement. Le modèle CNN classique s'est avéré être le plus performant, atteignant un taux de classification de 92,8%, suivi de près par DenseNet-121 avec un taux de classification de 92%. Ces performances prometteuses ouvrent la voie à des applications pratiques dans le domaine médical, notamment dans le diagnostic assisté par ordinateur des affections cutanées. Cependant, des recherches supplémentaires sont nécessaires pour explorer d'autres techniques d'optimisation et pour évaluer la généralisation des modèles sur des ensembles de données plus vastes et diversifiés. En somme, cette étude démontre le potentiel des modèles CNN dans le domaine de la santé, en particulier pour la classification précise des images médicales, ouvrant ainsi la voie à de futures avancées dans le diagnostic et la prise en charge des maladies cutanées.

Conclusion Générale

Conclusion

Ce travail de recherche a exploré l'application de l'apprentissage profond pour la classification des maladies de la peau, en mettant l'accent sur les réseaux de neurones convolutifs. Les résultats obtenus montrent que les modèles CNN peuvent atteindre des performances élevées dans la classification des images médicales. Grâce à des stratégies de prétraitement et d'optimisation innovantes, nos modèles ont atteint des taux de classification record de 92,8 % pour le modèle CNN classique et 92 % pour DenseNet-121, positionnant notre recherche à l'avant-garde de l'état de l'art actuel. Les modèles classiques et pré-entraînés ont été comparés, montrant que les modèles pré-entraînés peuvent être plus efficaces dans certaines situations, mais que les modèles classiques peuvent être plus flexibles et plus faciles à adapter à de nouvelles tâches.

Les résultats de cette étude démontrent le potentiel des modèles CNN dans le domaine de la santé, en particulier pour la classification précise des images médicales. Les améliorations apportées aux modèles existants, notamment par l'utilisation de techniques de prétraitement et d'équilibrage des données, ont permis d'atteindre des performances élevées dans la classification des maladies de la peau.

Cependant, des recherches supplémentaires sont nécessaires pour explorer d'autres techniques d'optimisation et pour évaluer la généralisation des modèles sur des ensembles de données plus vastes et diversifiés. De plus, il est important de poursuivre les recherches pour améliorer la robustesse et la fiabilité des modèles, ainsi que pour évaluer leur impact sur la pratique clinique.

En fin de compte, ce travail de recherche contribue à l'avancement de la recherche dans le domaine de l'apprentissage profond pour la classification des maladies de la peau, et ouvre la voie à de futures avancées dans le diagnostic et la prise en charge des maladies cutanées.

Limitations de l'étude

Notre étude présente quelques limitations qui pourraient affecter la portée et l'applicabilité des résultats :

1. *Nombre de classes limité*: nous nous sommes concentrés sur 9 classes de maladies de la peau, ce qui ne représente pas l'ensemble des affections dermatologiques. Cela pourrait limiter la capacité des modèles à généraliser à des cas non rencontrés lors de l'entraînement.

2. *Utilisation de bases de données existantes*: l'absence de collecte de notre propre ensemble de données nous a contraints à utiliser des bases de données existantes. La diversité et la représentativité des échantillons dans ces bases pourraient être sub-optimales, affectant la performance des modèles.
3. *Complexité des modèles*: les modèles plus complexes, comme DenseNet121, nécessitent des ressources de calcul importantes pour l'entraînement et l'inférence. Cela peut limiter leur déploiement dans des environnements où les ressources sont limitées.

Perspectives

Ces limitations soulignent l'importance de poursuivre les recherches dans les directions suivantes:

- *Élargir le spectre des maladies*: Inclure un plus grand nombre de classes de maladies de la peau pour améliorer la généralisation des modèles.
- *Constituer des ensembles de données de haute qualité*: Collecter et annoter des ensembles de données de manière plus rigoureuse pour garantir la diversité et la représentativité des échantillons.
- *Optimiser les modèles pour l'efficacité*: Explorer des techniques pour réduire la complexité des modèles et optimiser leur performance computationnelle.
- Exploration de nouvelles architectures CNN
- Utilisation d'autres techniques de prétraitement et d'équilibrage des données
- Évaluation sur des ensembles de données diversifiés
- Développement d'une application mobile basée sur notre modèle de classification des maladies de la peau.

Ces perspectives visent à orienter les futures recherches dans ce domaine, afin de continuer à améliorer les outils de diagnostic en dermatologie et à élargir les applications de l'apprentissage profond dans la médecine.

Bibliographie

- [1] BELAROUCI Sara. Traitement et classification des données médicales non équilibrées. Thèse de doctorat, Université de Tlemcen, 2016.
- [2] Kaggle. Skin Cancer 9 Classes ISIC. <https://www.kaggle.com/datasets/nodoubttome/skin-cancer9-classesisic>, (consulté le 20/04/2024).
- [3] Kaggle. Skin Cancer MNIST: HAM10000. <https://www.kaggle.com/datasets/kmader/skin-cancer-mnist-ham10000>, (consulté le 20/04/2024).
- [4] J. Hopfield. Réseaux de neurones et systèmes physiques avec des capacités informatiques collectives émergentes. Actes de l'Académie nationale des sciences des États-Unis d'Amérique, vol. 79, pp. 2554-2558, 1982.
- [5] O'Malley CD, Saunders JB. Leonardo da Vinci on the human body. Gramercy Books, New York, p. 55, 1983.
- [6] Deuxième Avis. Tout savoir sur la peau et les maladies dermatologiques. <https://www.deuxiemeavis.fr/blog/article/550-tout-savoir-sur-la-peau-et-les-maladies-dermatologiques>, (consulté le 20/04/2024).
- [7] Société française de dermatologie. Les fonctions de la peau : un organe multifonction, 2019. <https://dermato-info.fr/fr/c-est-quoi-la-peau/un-organe-multifonction> (consulté le 20/04/2024).
- [8] Société française de dermatologie. Mon dermatologue, quand le consulter ?, 2019. https://2019.dermato-info.fr/article/Quand_consulter (consulté le 25/04/2024).
- [9] Deuxiemeavis.fr. Fiche Maladies de la peau, 2020. <https://www.deuxiemeavis.fr/famille/maladies-de-la-peau> (consulté le 28/04/2024).
- [10] MSD Manuals. Description des lésions cutanées élémentaires. <https://www.msmanuals.com/fr/professional/troubles-dermatologiques/prise-en-charge-du-patient-atteint-de-troubles-dermatologiques/description-des-l%C3%A9sions-cutan%C3%A9es-%C3%A9l%C3%A9mentaires> (consulté le 23/04/2024).
- [11] HAMLADJI, Rose-Marie. Précis de Sémiologie. En ligne depuis : <https://www.sofiotheque.info/2016/09/precis-de-semiologie-rose-marie.html> (consulté le 28/04/2024).
- [12] Ligue contre le cancer. Les cancers de la peau. <https://boutique.liguecancer.ch/files/kl/webshop/PDFs/francais/les-cancers-de-la-peau-021084012111.pdf>.
- [13] Roche. Cancer Carcinome Basocellulaire. <https://www.roche.fr/articles/cancer-carcinome-basocellulaire> (consulté le 28/04/2024).

- [14] Hirslanden. Cancer blanc de la peau. <https://www.hirslanden.ch/fr/corporate/description-pathologies/cancer-blanc-de-la-peau.html> (consulté le 28/04/2024).
- [15] Dermatos. Les différents types de cancer de la peau. <https://dermatos.fr/le-dermato-soigne/les-differents-types-de-cancer-de-la-peau/> (consulté le 28/04/2024).
- [16] Journée Oncologie. Conférence cancer cutanés, octobre 2018. https://journeeoncologie.com/pdf/conference_cancer_cutanes_octobre2018.pdf
- [17] Deuxième Avis. Diagnostics et examens des maladies de peau. <https://www.deuxiemeavis.fr/blog/article/559-diagnostics-et-examens-des-maladies-de-peau> (consulté le 20/04/2024).
- [18] FONTAINE, S., et al. Artificial intelligence for skin cancer diagnosis: A systematic review. *JAMA Dermatology*, 157(12), 1527-1535, 2021. <https://jamanetwork.com/journals/jamadermatology/fullarticle/2697219>
- [19] HAENSSLE, H., et al. Automated melanoma detection using a deep learning convolutional neural network. *Journal of the National Cancer Institute*, 110(6), 794-802, 2018. <https://ieeexplore.ieee.org/document/9342142>
- [20] SIQUEIRA, F., et al. Skin lesion segmentation and classification using deep convolutional neural networks: A review. arXiv preprint arXiv:2004.02652, 2020. <https://arxiv.org/abs/2112.10307>
- [21] SINGH, P., JAIN, A. Clinical decision support systems for skin diseases: A comprehensive review. *Journal of Dermatology*, 148(12), 1820-1832, 2021. <https://www.semanticscholar.org/paper/Clinical-Decision-Support-Systems-Teufel-Binder/36ebb48938acceeaf9944aa0021a02852ae6ed2f>
- [22] CHEN, H., et al. Dermatologist-level diagnosis of skin lesions using a large dataset of clinically annotated images. *Nature Medicine*, 26(7), 1011-1017, 2020. <https://www.nature.com/articles/s41597-023-02630-0>
- [23] WANG, T., et al. Intelligent clinical decision support systems for skin disease diagnosis. *Expert Systems with Applications*, 182, 115185, 2021. <https://www.mdpi.com/2234058>
- [24] LIU, Y., et al. A Dermatologist-Level Artificial Intelligence Classifier for Skin Disease Diagnosis. *Nature Medicine*, 26(7), 1003-1010, 2020. <https://www.nature.com/articles/s41467-023-43095-4>
- [25] CORNUÉJOLS, Antoine, et al. Apprentissage artificiel: Concepts et algorithmes. Paris : Eyrolles, 2009.
- [26] Jérôme Buisine. Méthodes d'apprentissage automatique pour la prise en compte du bruit dans les images de synthèse. Thèse de doctorat, Université du Littoral Côte d'Opale. 2021
- [27] ELAOUABER Zineb Aziza. Système d'aide au diagnostic pour la détection automatique du Glaucome et de la Rétinopathie diabétique. Thèse de doctorat, Université de Tlemcen, 2023.
- [28] Eugene Charniak. Introduction au Deep Learning. Dunod, 2021

- [29] TOUAHRI Radia. L'Apprentissage Profond pour la Classification et l'Interprétation d'Images. Thèse de doctorat, Université de Badji Mokhtar Annaba, 2023.
- [30] He, K., Zhang, X., Ren, S., & Sun, J. Deep Residual Learning for Image Recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 770-778, 2016.
- [31] Aswin Vellaichamy S. et al.; MULTIPLE PLANT LEAF DISEASE CLASSIFICATION USING DENSENET-121 ARCHITECTURE. *International Journal of Electrical Engineering and Technology (IJEET)*. Vol.12, pp.38-57, 2021.
- [32] Howard, A. G.; Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., ... & Adam, H. Mobilenets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*, 2017.
- [33]. Srinivasu, P.N.; SivaSai, J.G.; Ijaz, M.F.; Bhoi, A.K.; Kim, W.; Kang, J.J. Classification of Skin Disease Using Deep Learning Neural Networks with MobileNet V2 and LSTM. *Sensors* 2021, 21, 2852, 2021. <https://www.mdpi.com/1424-8220/21/8/2852>
- [34] Shetty, B.; Fernandes, R.; Rodrigues, A.P.; Chengoden, R.; Bhattacharya, S.; Lakshmana, K. Skin lesion classification of dermoscopic images using machine learning and convolutional neural network. *Sci. Rep.*, 12, 18134, 2022. <https://pubmed.ncbi.nlm.nih.gov/36307467/>
- [35] ALMUAYQIL, S.N., ABD EL-GHANY, S., ELMOGY, M. Computer-Aided Diagnosis for Early Signs of Skin Diseases Using Multi Types Feature Fusion Based on a Hybrid Deep Learning Model. *Electronics*, 11, 4009, 2022. <https://www.mdpi.com/2079-9292/11/23/4009>
- [36] HOSSAIN, S.I., DE GOËR DE HERVE, J., HASSAN, M.S., MARTINEAU, D., PETROSYAN, E., CORBIN, V., et al. Exploring convolutional neural networks with transfer learning for diagnosing Lyme disease from skin lesion images. *Comput. Methods Programs Biomed.*, 215, 106624, 2022. <https://www.sciencedirect.com/science/article/abs/pii/S016926072>
- [37] ALI, K., SHAIKH, Z.A., KHAN, A.A., LAGHARI, A.A. Multiclass skin cancer classification using EfficientNets—A first step towards preventing skin cancer. *Neurosci. Inform.*, 2, 100034, 2022. <https://www.sciencedirect.com/science/article/pii/S2772528621000340?via%3Dihub>
- [38] INTHIYAZ, S., ALTAHAN, B.R., AHAMMAD, S.H., RAJESH, V., KALNGI, R.R., SMIRANI, L.K., HOSSAIN, M.A., RASHED, A.N.Z. Skin disease detection using deep learning. *Adv. Eng. Softw.*, 175, 103361, 2023. <https://www.sciencedirect.com/science/article/abs/pii/S0965997822002629?via%3Dihub>
- [39] WEI, M., WU, Q., JI, H., WANG, J., LYU, T., LIU, J., ZHAO, L. A Skin Disease Classification Model Based on DenseNet and ConvNeXt Fusion. *Electronics*, 12, 438, 2023. <https://www.mdpi.com/2079-9292/12/2/438>
- [40] Python Software Foundation. <https://www.python.org/doc/essays/blurb/>, (consulté le 20/04/2024).
- [41] Kaggle. <https://www.kaggle.com/datasets>, (consulté le 20/04/2024).

- [42] ALAM, Talha Mahboob, et al. An Efficient Deep Learning-Based Skin Cancer Classifier for an Imbalanced Dataset. *Diagnostics*, 12, 2115, 2022. <https://doi.org/10.3390/diagnostics12092115>
- [43] SU, QICHEN, et al. A GAN-Based Data Augmentation Method for Imbalanced Multi-Class Skin Lesion Classification, *IEEE Access*, vol. 12, pp. 16498-16513, 2024.