

RÉPUBLIQUE ALGÉRIENNE DÉMOCRATIQUE ET POPULAIRE  
MINISTÈRE DE L'ENSEIGNEMENT SUPÉRIEUR ET DE LA RECHERCHE  
SCIENTIFIQUE  
UNIVERSITÉ ABDERRAHMAN MIRA - BEJAIA  
FACULTÉ SCIENCES EXACTES  
DÉPARTEMENT INFORMATIQUE



MÉMOIRE DE FIN DE CYCLE EN VUE DE L'OBTENTION DU  
DIPLOME DE MASTER RECHERCHE  
OPTION INTELLIGENCE ARTIFICIEL

---

# Diagnostic du mélanome à l'aide de l'apprentissage profond

---

Réalisé par :

**M<sup>r</sup> AMRANE Lotfi**

Devant le jury d'examen composé de :

M <sup>r</sup> K. AMROUN :	Professeur	U. A/Mira Béjaia.	Président
M <sup>r</sup> F. BOUCHEBBAH :	Maître de Conf. B	U. A/Mira Béjaia.	Examineur
M <sup>me</sup> H. GADOUCHE :	Maître de Conf. B	U. A/Mira Béjaia.	Encadrante

Promotion : 2022/2023

---

## *Remerciements*

---

Tout d'abord, ma profonde gratitude est adressée à Dieu "ALLAH", pour m'avoir octroyé la force, le courage et la patience nécessaires à la finalisation de ce projet.

Un mémoire est le fruit d'un effort collaboratif, où chaque contribution, aussi minime soit-elle, est essentielle et inestimable. Cette expérience m'a conforté dans l'idée que rien n'est insurmontable et que c'est l'union qui crée la force.

Ma sincère reconnaissance va à mon encadrante, Mme. GADOUCHE HANIA. Grâce à elle, j'ai eu l'opportunité de travailler sur un sujet pertinent et d'importance majeure pour de nombreuses personnes.

Je tiens aussi à exprimer ma gratitude aux membres du jury, Mr. AMROUN KAMAL et Mr. BOUCHEBBAH FATAH, pour l'attention qu'ils ont portée à mon travail, acceptant non seulement de le réviser, mais aussi de le bonifier avec leurs suggestions.

En conclusion, je remercie du fond du cœur toutes les personnes qui ont contribué directement ou indirectement à ce projet. Une mention spéciale à mes parents, mes piliers, qui m'ont inculqué des valeurs telles que la persévérance, l'intégrité et une passion profonde pour le travail bien fait.

---

## *Dédicaces :*

---

Je dédie ce travail à :

À mes précieux parents, qui sont pour moi bien plus que les mots ne peuvent le décrire. À ces piliers, mes sources intarissables d'inspiration et de motivation, qui m'ont constamment soutenue et façonnée en la personne que je suis. Aucuns mots ne peuvent véritablement rendre hommage à la profondeur de mon respect, de mon amour, de mon admiration, et de ma gratitude pour les sacrifices que vous avez consentis pour moi au fil des ans. Que le Très-Haut vous comble de bonheur, de joie, de santé et vous offre une longue vie.

À chacune et chacun qui a contribué à ce projet, que ce soit de près ou de loin. Votre engagement et votre patience ont été essentiels à l'aboutissement de ce travail.

À la précieuse fratrie d'amis que j'ai eu l'honneur de connaître. À nos souvenirs impérissables. Aux instants partagés. Je vous souhaite un avenir lumineux, couronné de bonheur et de succès. Avec toute mon affection,

**AMRANE Lotfi.**

# Table des matières

<b>1</b>	<b>Introduction Générale</b>	<b>10</b>
1.1	Introduction . . . . .	10
1.2	problématique . . . . .	10
1.3	Objectifs . . . . .	11
1.4	Méthodologie de la recherche . . . . .	12
1.5	Organisation du mémoire . . . . .	12
<b>2</b>	<b>Généralités</b>	<b>14</b>
2.1	Introduction . . . . .	14
2.2	Définition du mélanome . . . . .	14
2.3	Les causes du mélanome . . . . .	15
2.4	Types du mélanome . . . . .	16
2.4.1	le mélanome superficiel extensif . . . . .	16
2.4.2	le mélanome lentigo malin . . . . .	16
2.4.3	le mélanome nodulaire . . . . .	16
2.4.4	le mélanome acrolentigineux (ou mélanome des extrémités) . . . . .	16
2.5	Les statistiques sur le mélanome . . . . .	17
2.6	Les signes et les symptômes du mélanome . . . . .	18
2.7	Comment évolue le mélanome? . . . . .	19
2.8	Stades et Traitements du Mélanome . . . . .	19
2.9	L'importance de la détection précoce du mélanome pour la santé . . . . .	21
2.10	Approches d'analyse des images dermoscopiques . . . . .	21
2.10.1	Méthode de la règle ABCD . . . . .	21
2.10.2	Méthode de la règle ABCD-E . . . . .	22
2.10.3	Méthode des 7 points de la liste de contrôle . . . . .	22
2.10.4	Méthode de Menzies . . . . .	22
2.10.5	Méthode d'analyse de motifs . . . . .	23
2.11	Application des techniques de l'intelligence artificielle dans le diagnostic médical	23
2.11.1	Contexte et importance de l'intelligence artificielle dans le domaine médical	23
2.11.2	Techniques de l'apprentissage automatique pour la classification et la prédiction du mélanome . . . . .	23
2.11.3	Machine Learning . . . . .	24
2.11.4	Types d'algorithmes du Machine Learning . . . . .	24
2.11.5	Apprentissage supervisé . . . . .	24
2.11.6	Apprentissage non supervisé . . . . .	24
2.11.7	Apprentissage par renforcement . . . . .	25
2.11.8	Deep Learning . . . . .	25
2.11.9	Types d'algorithmes du Deep Learning . . . . .	26

2.11.10	Sur apprentissage et Sous apprentissage . . . . .	30
2.11.11	Différence entre le Machine Learning et le Deep Learning . . . . .	31
2.11.12	Les fonctions d’activations usuelles . . . . .	32
2.11.13	Fonction sigmoïde . . . . .	32
2.11.14	Fonction softmax . . . . .	33
2.11.15	Fonction ReLu . . . . .	33
2.11.16	Fonction Leaky ReLU . . . . .	34
2.11.17	Fonction Hyperbolic tangent (TanH) . . . . .	35
2.11.18	Fonction Unité exponentielle linéaire (ELU) . . . . .	36
2.11.19	Limite des techniques de l’intelligence artificielle dans le diagnostic médical . . . . .	37
2.11.20	Défis de l’intelligence artificielle dans le diagnostic médical . . . . .	38
2.12	Conclusion . . . . .	39
<b>3</b>	<b>Etat de l’art</b>	<b>40</b>
3.1	Introduction . . . . .	40
3.2	Travaux connexes . . . . .	40
3.3	Exploration approfondie et comparaison des diverses approches . . . . .	43
3.4	Conclusion . . . . .	60
<b>4</b>	<b>Approche proposée</b>	<b>61</b>
4.1	Introduction . . . . .	61
4.2	Disséquer notre approche en détail . . . . .	61
4.2.1	Collecte des données . . . . .	62
4.2.2	Prétraitement . . . . .	63
4.3	Choix des architectures CNN pour la classification . . . . .	72
4.3.1	Transfer learning . . . . .	72
4.3.2	ResNet-50 . . . . .	73
4.3.3	DenseNet-201 . . . . .	74
4.3.4	InceptionResNetV2 . . . . .	76
4.3.5	Xception . . . . .	76
4.3.6	MobileNet . . . . .	77
4.4	Wisdom of Crowds . . . . .	77
4.4.1	Ensemble learning . . . . .	78
4.5	Conclusion . . . . .	79
<b>5</b>	<b>Expérimentation et évaluation</b>	<b>80</b>
5.1	Introduction . . . . .	80
5.2	Environnement de développement . . . . .	80
5.2.1	Langage de programmation . . . . .	81
5.2.2	Bibliothèques de Python . . . . .	81
5.3	Métriques d’évaluation des performances . . . . .	84
5.3.1	Matrice de confusion . . . . .	84
5.3.2	Accuracy . . . . .	85
5.3.3	La précision . . . . .	85
5.3.4	Recall . . . . .	85
5.3.5	F1-score . . . . .	86
5.3.6	Aire sous la Courbe ROC (AUC-ROC) : . . . . .	86
5.4	Importation des modèles pré-entraînés . . . . .	87
5.5	Compilation des modèles . . . . .	88

## TABLE DES MATIÈRES

---

5.6	Optimisation et Sauvegarde du Modèle à l'Aide de Callbacks . . . . .	89
5.7	Entraînement du Modèle . . . . .	90
5.8	Analyse de la Convergence du Modèle . . . . .	91
5.8.1	Discussion . . . . .	93
5.9	Analyse Comparative des Modèles . . . . .	94
5.9.1	Discussion . . . . .	97
5.9.2	Comparaison avec d'Autres Approches . . . . .	97
5.10	Construction d'un système de classification . . . . .	98
5.11	Conclusion . . . . .	100
	Conclusion générale . . . . .	101
	Bibliographie . . . . .	101

# Table des figures

1.1	bénin vs malign melanoma [1] . . . . .	11
2.1	Mélanome vs Nævus : Une Étude Visuelle. [42] . . . . .	15
2.2	Types de mélanomes et indices de propagation. [45] . . . . .	17
2.3	Taux standardisés par âge du mélanome en 2018 dans les 20 . . . . .	18
2.4	Les stades de melanome.[5] . . . . .	20
2.5	Application de la règle ABCD sur une tâche Naevus pigmentaire et un méla- nome. [6] . . . . .	21
2.6	Application de la règle ABCD-E. [7] . . . . .	22
2.7	Examen dermoscopique. Illustration des critères utilisés dans la méthode des 7 points de la liste de contrôle. [3] . . . . .	22
2.8	Un aperçu historique des avancées en Intelligence Artificielle et en Apprentissage Automatique (IA et ML). [24] . . . . .	24
2.9	Types des algorithmes de machine learning. [47] . . . . .	25
2.10	Architecture d'un perceptron multicouche (PMC). [26] . . . . .	26
2.11	CNN : le voyage d'une image à travers des couches neuronales. [46] . . . . .	27
2.12	Illustration schématique d'une opération de convolution. ( Mise en évidence de l'extraction des caractéristiques spatiales à travers le décalage du noyau de convolution.) [30] . . . . .	28
2.13	Représentation schématique d'une opération de pooling. ( Mise en évidence du processus de réduction des dimensions et de préservation des caractéristiques clés.) [31] . . . . .	28
2.14	Étapes du Pooling au Flattening vers une Couche Entièrement Connectée [32]	29
2.15	Types de réseaux de neurones en Deep Learning. [35] . . . . .	30
2.16	Overfitting et underfitting. [102] . . . . .	31
2.17	Différence entre le Machine Learning et le Deep Learning. [23] . . . . .	31
2.18	Représentation graphique de la fonction sigmoïde et de sa dérivée. [36] . . . . .	33
2.19	Représentation graphique de la fonction ReLu et de sa dérivée. [36] . . . . .	34
2.20	Représentation graphique de la fonction Leaky ReLu et de sa dérivée. [36] . . . . .	35
2.21	Représentation graphique de la fonction Tanh et de sa dérivée. [36] . . . . .	36
2.22	Représentation graphique de la fonction ELU et de sa dérivée. [36] . . . . .	37
4.1	La stratégie adoptée et les différentes étapes qui la constituent. . . . .	62
4.2	Distribution des données d'entraînement par Classe. . . . .	64
4.3	Distribution des données de test par Classe. . . . .	64
4.4	Aperçu visuel de l'ensemble de données. . . . .	65
4.5	Distribution des données d'entraînement par classe après le sous-échantillonnage	66
4.6	Distribution par classe du nouvel ensemble d'entraînement après la division. . . . .	68
4.7	Distribution par classe de l'ensemble de validation après la division. . . . .	68

4.8	Chargement et redimensionnement des images. . . . .	69
4.9	Les différentes augmentations de données utilisées. . . . .	70
4.10	Visualisation des Résultats de l’Augmentation des Images. . . . .	71
4.11	Un Regard graphique sur le transfert d’apprentissage. [55] . . . . .	73
4.12	Analyse complète de l’architecture ResNet-50. [56] . . . . .	74
4.13	Analyse complète de l’architecture DenseNet-201. [60] . . . . .	75
4.14	Analyse complète de l’architecture InceptionResNetV2. [62] . . . . .	76
4.15	Analyse complète de l’architecture Xception. [66] . . . . .	77
4.16	illustration du processus de fusion des prédictions par un vote majoritaire. . .	79
5.1	Logo de kaggle. [100] . . . . .	80
5.2	Logo de python. [89] . . . . .	81
5.3	Logo de pandas. [88] . . . . .	81
5.4	Logo de matplotlib. [86] . . . . .	82
5.5	Logo de seaborn. [83] . . . . .	82
5.6	Logo de numpy. [87] . . . . .	83
5.7	Logo de tensorflow. [87] . . . . .	83
5.8	Logo de keras. [85] . . . . .	83
5.9	Logo de Scikit-learn. [94] . . . . .	84
5.10	Matrice de confusion. [96] . . . . .	84
5.11	Courbe ROC-AUC. [98] . . . . .	86
5.12	Importation du modèle DenseNet-201. . . . .	87
5.13	Importation du modèle ResNet-50. . . . .	87
5.14	Importation du modèle InceptionResNetV2. . . . .	87
5.15	Importation du modèle Xception. . . . .	87
5.16	Importation du modèle MobileNet. . . . .	88
5.17	Modification d’Architecture pour les Modèles Pré-entraînés . . . . .	89
5.18	Liste des rappels utilisés. . . . .	90
5.19	Phase d’entraînement du modèle. . . . .	91
5.20	Évolution de l’accuracy et de la Loss durant l’entraînement et la validation pour DenseNet201 . . . . .	91
5.21	Évolution de l’accuracy et de la Loss durant l’entraînement et la validation pour ResNet50. . . . .	92
5.22	Évolution de l’accuracy et de la Loss durant l’entraînement et la validation pour InceptionResNet. . . . .	92
5.23	Évolution de l’accuracy et de la Loss durant l’entraînement et la validation pour Xception. . . . .	93
5.24	Évolution de l’accuracy et de la Loss durant l’entraînement et la validation pour MobileNet. . . . .	93
5.25	Matrice de confusion du modèle DenseNet201. . . . .	94
5.26	Matrice de confusion du modèle ResNet50. . . . .	95
5.27	Matrice de confusion du modèle InceptionResNet. . . . .	95
5.28	Matrice de confusion du modèle Xception. . . . .	96
5.29	Matrice de confusion du modèle MobileNet. . . . .	96
5.30	Illustration de l’utilisation du vote majoritaire. . . . .	99

# Liste des tableaux

- 2.1 Tableau comparatif entre le Machine Learning et le Deep Learning. [28] . . . . 32
- 3.1 Table comparative . . . . . 59
- 5.1 Tableau comparatif entre nos différents modèles. . . . . 97
- 5.2 Tableau comparatif entre différentes approches. . . . . 98

## Résumé

Le mélanome est un type de cancer de la peau potentiellement mortel, dont la prise en charge précoce est cruciale pour augmenter les chances de traitement réussi. Identifier précocement les signes et symptômes du mélanome est donc primordial, en particulier chez les individus à risque. Face à la complexité de la détection précoce du mélanome, l'apprentissage automatique, et plus précisément le transfert d'apprentissage, offre des possibilités intéressantes. Dans cette étude, nous avons entraîné cinq modèles de transfert d'apprentissage distincts, exploitant les capacités de ces modèles à utiliser des connaissances pré-acquises pour des tâches spécifiques au mélanome. Afin d'optimiser davantage les performances prédictives, ces modèles ont été combinés en utilisant une technique d'ensemble learning, où nous avons opté pour une stratégie de vote majoritaire. Ce choix permet d'obtenir une prédiction consensuelle à partir des prédictions individuelles de chaque modèle, renforçant ainsi la robustesse et la fiabilité de notre approche. Les résultats obtenus à l'issue de cette combinaison sont prometteurs.

**Mots clés** : Melanome, Classification, Dataset, CNN, Transfer learning, DenseNet-201, ResNet-50, Inception-ResNet, Xception, MobileNet

## Abstract

The melanoma is a potentially deadly type of skin cancer, and early management is crucial to increase the chances of successful treatment. Identifying the signs and symptoms of melanoma early on is therefore paramount, especially in individuals at risk. Given the complexity of early melanoma detection, machine learning, specifically transfer learning, offers interesting possibilities. In this study, we trained five distinct transfer learning models, leveraging these models' abilities to use pre-existing knowledge for melanoma-specific tasks. To further optimize predictive performance, these models were combined using an ensemble learning technique, where we chose a majority vote strategy. This choice allows us to obtain a consensus prediction from the individual predictions of each model, thereby enhancing the robustness and reliability of our approach. The results obtained from this combination are promising.

**Keywords** : Melanoma, Classification, Dataset, CNN, Transfer learning, DenseNet-201, ResNet-50, Inception-ResNet, Xception, MobileNet.

# Chapitre 1

## Introduction Générale

### 1.1 Introduction

L'intelligence artificielle (IA) et l'apprentissage automatique (Machine Learning) sont des domaines de recherche en plein essor dans de nombreux secteurs, y compris la médecine. Ces technologies peuvent aider à analyser et à interpréter de grandes quantités de données pour fournir des estimations et des prédictions utiles aux professionnels de santé.

Le mélanome est un type de cancer de la peau qui est souvent difficile à diagnostiquer à un stade précoce, ce qui peut entraîner des complications graves. Les méthodes de diagnostic traditionnelles telles que l'examen clinique, la dermatoscopie et la biopsie peuvent être limitées dans leur précision et leur efficacité. Cependant, l'utilisation de l'apprentissage en profondeur (Deep Learning) pour analyser des images de la peau peut aider les professionnels de santé à détecter les signes précoces du mélanome et à établir un diagnostic précis.

Le but de cette recherche est d'explorer l'application de l'apprentissage en profondeur à la détection du mélanome et ses implications pour la pratique clinique. Nous discuterons des différentes méthodes d'apprentissage en profondeur utilisées pour analyser les images de la peau et évaluerons leur précision et leur fiabilité. Nous examinerons également les avantages et les limitations de l'utilisation de l'apprentissage en profondeur pour la détection du mélanome, ainsi que les implications pour la pratique clinique.

En fin de compte, l'utilisation de l'apprentissage en profondeur pour la détection du mélanome peut améliorer la précision et l'efficacité du diagnostic, aider les professionnels de santé à détecter les signes précoces du mélanome et améliorer les résultats pour les patients atteints de cette maladie. Cependant, il est important de comprendre les limites de cette technologie et de l'utiliser en combinaison avec d'autres méthodes de diagnostic pour fournir les meilleurs résultats pour les patients.

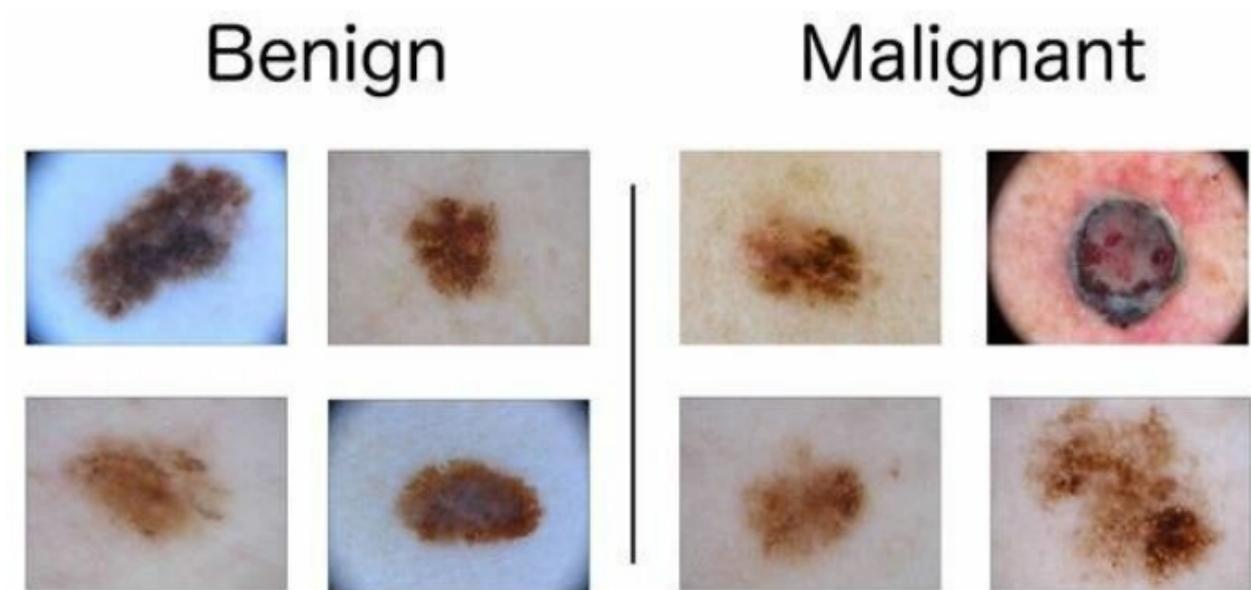
### 1.2 problématique

En raison de l'importance du diagnostic précoce du mélanome pour améliorer les résultats des patients, les professionnels de la santé cherchent à utiliser des techniques innovantes pour améliorer la précision du diagnostic. L'apprentissage en profondeur offre une méthode prometteuse pour aider à identifier les signes précoces du mélanome à partir d'images de la peau. Cependant, malgré les progrès dans ce domaine, il reste des défis à surmonter pour améliorer la précision et la fiabilité des résultats, notamment en termes de sélection des caractéristiques les plus pertinentes et de réduction des faux positifs. La question clé est donc de savoir comment l'apprentissage en profondeur peut être utilisé de manière optimale pour améliorer le

diagnostic du mélanome, tout en surmontant les défis associés à cette approche.

### 1.3 Objectifs

Ce mémoire vise à améliorer la précision du diagnostic du mélanome en utilisant des méthodes basées sur l'apprentissage en profondeur appliqué à des images de la peau. Notre approche, baptisée "Transfer Learning with Ensembles of Deep Neural Networks for Skin Cancer," a pour objectif principal de développer un modèle de prédiction robuste et fiable pour aider les professionnels de la santé à détecter le mélanome plus tôt, améliorant ainsi les résultats pour les patients atteints de cette maladie. Pour ce faire, nous appliquerons des techniques d'apprentissage en profondeur pour extraire les caractéristiques les plus pertinentes des images de la peau, permettant de détecter le mélanome avec une haute précision. Nous utiliserons des méthodes de classification pour classer les images selon qu'elles sont bénignes ou malignes. Notre objectif ultime est de proposer une méthode de diagnostic du mélanome à l'aide de l'apprentissage en profondeur qui peut être utilisée pour améliorer les soins de santé pour les patients atteints de cette maladie.



Benign and malignant melanoma

FIGURE 1.1 – bénin vs malign melanoma [1]

## 1.4 Méthodologie de la recherche

Notre méthodologie de recherche se compose de plusieurs étapes clés :

- Étape de recherche et d’analyse : Dans cette étape, nous avons effectué une recherche approfondie de l’état de l’art en matière de classification du mélanome à l’aide de réseaux de neurones convolutifs. Nous avons analysé les différentes approches proposées par les chercheurs dans ce domaine en évaluant leurs performances à l’aide de mesures telles que la précision, la sensibilité et la spécificité. Nous avons également comparé les avantages et les limites des différentes approches pour identifier les lacunes à combler dans ce domaine.
- Étape d’identification du problème et de la proposition d’une solution : Dans cette étape, nous avons identifié la problématique de la classification du mélanome et proposé une solution basée sur l’utilisation de réseaux de neurones convolutifs. Nous avons défini les objectifs de notre étude, les hypothèses à tester et les questions de recherche à répondre.
- Étape d’implémentation et d’expérimentation du système proposé : Dans cette étape, nous avons mis en œuvre le système proposé et effectué des expériences pour évaluer ses performances en utilisant des données de validation et de test. Nous avons effectué des prétraitements sur les images de mélanome, entraîné et testé les réseaux de neurones convolutifs, et évalué les performances du système en termes de précision, de sensibilité et de spécificité. Nous avons également effectué une analyse approfondie des résultats pour comprendre les avantages et les limites de notre approche et proposer des pistes d’amélioration pour de futures recherches.

En résumé, notre méthodologie de recherche comprend une analyse approfondie de l’état de l’art, une identification claire de la problématique et une proposition d’une solution basée sur des réseaux de neurones convolutifs, ainsi qu’une mise en œuvre et une évaluation rigoureuse de notre système proposé.

## 1.5 Organisation du mémoire

Le deuxième chapitre se concentrera sur une présentation approfondie de la maladie du mélanome, un type de cancer de la peau. Nous aborderons sa définition, ses causes, ses symptômes, ses stades de progression, ses complications potentielles ainsi que les traitements disponibles. En outre, nous examinerons les diverses techniques de l’intelligence artificielle (IA) qui trouvent application dans le domaine du diagnostic médical, tout en mettant en évidence celles qui sont spécifiquement adaptées à notre problème particulier, tout en abordant les défis et les limites spécifiques de l’IA dans le contexte médical.

Dans le troisième chapitre, nous allons effectuer une revue de la littérature pour présenter notre état de l’art des travaux de recherche les plus importants dans le domaine du diagnostic du mélanome à partir d’images de la peau. Nous synthétiserons les grandes lignes de chaque document et procéderons à une analyse comparative des différentes approches proposées en les présentant dans un tableau.

Le quatrième chapitre portera sur la description de notre approche de diagnostic à partir de l’apprentissage en profondeur. Nous présenterons les différentes étapes de notre méthode, notamment la préparation des données, la construction des modèles CNN, l’entraînement et l’évaluation.

Dans le cinquième chapitre, nous présenterons les résultats de notre étude expérimentale en utilisant des métriques de performance telles que la précision, la sensibilité et la spécificité.

Nous décrirons également les outils de programmation utilisés et les logiciels choisis pour l'implémentation de notre système.

Enfin, ce mémoire se clôturera par une conclusion générale qui présentera les perspectives de ce travail. Nous discuterons des limites de notre approche et des axes d'amélioration pour les travaux futurs.

# Chapitre 2

## Généralités

### 2.1 Introduction

Le mélanome cutané, une variante du cancer du mélanome, prend naissance dans les mélanocytes, les cellules responsables de la production de mélanine. Cette maladie surgit lorsque ces mélanocytes subissent des mutations et commencent à se multiplier de manière incontrôlée. Étant en charge de la pigmentation de la peau, les mélanocytes jouent un rôle crucial dans notre apparence. Le mélanome cutané se manifeste souvent par des changements visibles au niveau des taches pigmentaires ou des grains de beauté existants.

Parmi les signes d'alerte les plus fréquents, on observe des modifications dans la taille, la forme, la couleur ou la texture d'une lésion cutanée. Des facteurs tels qu'une exposition excessive au soleil, des antécédents familiaux de mélanome, ainsi qu'une peau claire et des coups de soleil fréquents augmentent le risque de développement de cette maladie.

La détection précoce du mélanome cutané revêt une importance capitale, car il peut rapidement métastaser vers d'autres régions du corps, ce qui rend le traitement plus complexe. Des mesures de prévention comme une protection solaire adéquate et un examen régulier de la peau s'avèrent essentielles pour réduire le risque de mélanome cutané.

### 2.2 Définition du mélanome

Le mélanome est l'une des formes les plus graves de cancer de la peau (cutanés). Même s'il ne représente que 10 % des cancers cutanés, le mélanome est à l'origine de la grande majorité des décès dus à ce type de cancer. Il se manifeste généralement comme une tache pigmentée sur la peau, qui peut varier en couleur de brun foncé à noir, ou même rouge-rosé chez les personnes à peau claire. Cette tache évolue rapidement, changeant de forme et de couleur au fil du temps. Dans 80 % des cas, le mélanome apparaît sur une peau saine, sans tache ou lésion préexistante, tandis que dans les 20 % restants, il évolue à partir d'un grain de beauté préexistant (aussi appelé *nævus*). Le mélanome commence son développement dans l'épiderme, la couche supérieure de la peau, à partir de cellules appelées mélanocytes. À ce stade initial, il est connu sous le nom de "mélanome in situ" et ne présente pas de risque de métastase. Cependant, sans traitement approprié, il peut progresser en profondeur, atteignant le derme et même l'hypoderme, devenant ainsi invasif et capable de métastaser. Près de 25 % des mélanomes en France sont diagnostiqués à un stade avancé. Pour cette raison, il est important de connaître les modalités de sa prévention et de son dépistage. [39] [40] [41]

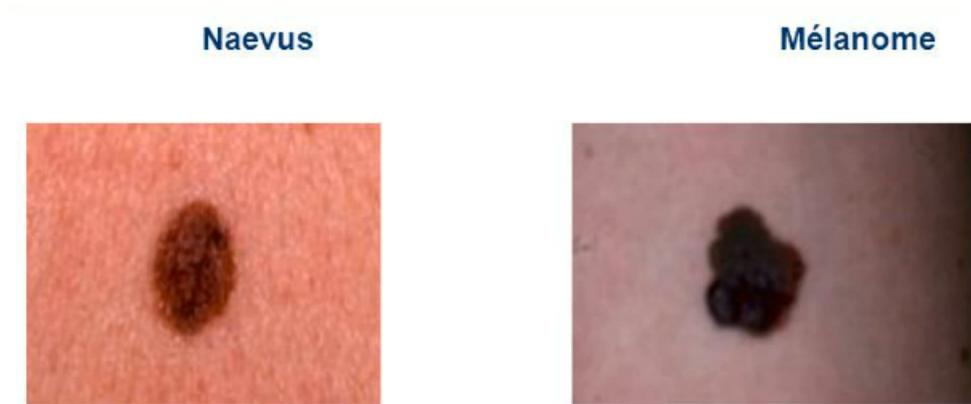


FIGURE 2.1 – Mélanome vs Nævus : Une Étude Visuelle. [42]

## 2.3 Les causes du mélanome

Le mélanome est un type de cancer de la peau particulièrement agressif, dont la compréhension des causes est essentielle pour la prévention et le traitement. Ce cancer peut se développer en raison de divers facteurs environnementaux, génétiques et physiologiques. Les principales causes sont les suivantes :

### Facteurs de risque externes :

- Exposition au soleil et aux ultraviolets artificiels [43]
- Antécédents de coups de soleil, notamment reçus pendant l'enfance [43]

### Facteurs de risque internes :

- Le phototype définissant la sensibilité de la peau aux rayonnements ultraviolets. Il existe plusieurs classifications de phototypes, avec certains étant plus à risque que d'autres, comme ceux ayant la peau claire avec cheveux roux ou blonds, yeux clairs, et des taches de rousseur [43]
- Une sensibilité accrue face au soleil, notamment une peau ayant une tendance à brûler et ne bronze pas ou peu [43]
- Présence d'un nombre élevé de grains de beauté (plus de 50), d'aspect inhabituel ou congénitaux (c'est-à-dire présents depuis la naissance) de grande taille [43]
- Antécédents personnels ou familiaux de mélanome. En présence de plusieurs cas de mélanome diagnostiqués au sein d'une même famille, une consultation d'oncogénétique peut être proposée à la recherche d'un gène prédisposant au mélanome [43]
- Immunodépression, qui se caractérise par un affaiblissement du système immunitaire [43]
- Il convient de noter que le mélanome cutané peut se manifester à tout âge, avec un pic d'incidence entre 50 et 64 ans pour les hommes et entre 15 et 64 ans pour les femmes. L'avancée en âge peut augmenter le risque de développer un mélanome [44].

## 2.4 Types du mélanome

On distingue quatre principaux types de mélanomes de la peau :

### 2.4.1 le mélanome superficiel extensif

Le mélanome superficiel extensif est l'un des types les plus courants de mélanome, représentant 60 à 70 % des cas. Cette forme de mélanome est souvent associée à des coups de soleil significatifs subis par le passé. Au début, sa progression est horizontale, s'étendant à la surface de la peau. Ensuite, il s'infiltré en profondeur dans les différentes couches cutanées. Il se manifeste généralement comme une tache irrégulière de couleur brune ou noire. Cette tache évolue lentement sur une période de un à cinq ans, puis sa transformation s'accélère. Chez les hommes, le mélanome superficiel extensif est le plus souvent localisé sur le cou et la partie supérieure du tronc, tandis que chez les femmes, il apparaît fréquemment sur la partie inférieure des jambes. [39]

### 2.4.2 le mélanome lentigo malin

Le mélanome de Dubreuilh, également connu sous le nom de mélanome de type lentigo malin, se manifeste généralement chez les personnes âgées de plus de 50 ans, représentant de 5 à 10 % des cas. Cette forme de mélanome est principalement causée par des expositions répétées aux rayons ultraviolets du soleil. Son expansion commence initialement de manière horizontale avant de devenir verticale. Les zones de prédilection pour son apparition sont celles exposées au soleil, notamment le visage, le cou et les mains. Les symptômes se présentent sous la forme d'une tache brune de teinte variable, qui tend à augmenter de taille très lentement. [39]

### 2.4.3 le mélanome nodulaire

Le mélanome nodulaire se distingue par sa capacité de croissance particulièrement rapide parmi les divers types de mélanomes. Il peut atteindre toutes les parties de la peau, y compris les régions non exposées au soleil. Il représente moins de 5 % des mélanomes de la peau. Contrairement aux autres mélanomes qui commencent à s'étendre horizontalement, le mélanome nodulaire s'étend rapidement en profondeur (verticalement) dans les couches de la peau. Il se manifeste habituellement sous la forme d'une surélévation de la peau de couleur foncée ou de couleur « peau normale ». [39]

### 2.4.4 le mélanome acrolentigineux (ou mélanome des extrémités)

Le mélanome acrolentigineux, aussi appelé mélanome des extrémités, est généralement observé chez les individus à la peau plus foncée, apparaissant fréquemment sur la paume des mains, la plante des pieds ou sous les ongles. Il n'est pas lié à une surexposition aux ultraviolets et se développe d'abord horizontalement pendant plusieurs mois ou années, puis verticalement, en profondeur. Il apparaît habituellement sous la forme d'une lésion foncée plane puis sous forme de nodules. Lorsqu'il est de la couleur de la peau, il est alors très difficile à diagnostiquer car il peut être confondu avec une verrue plantaire. [39]

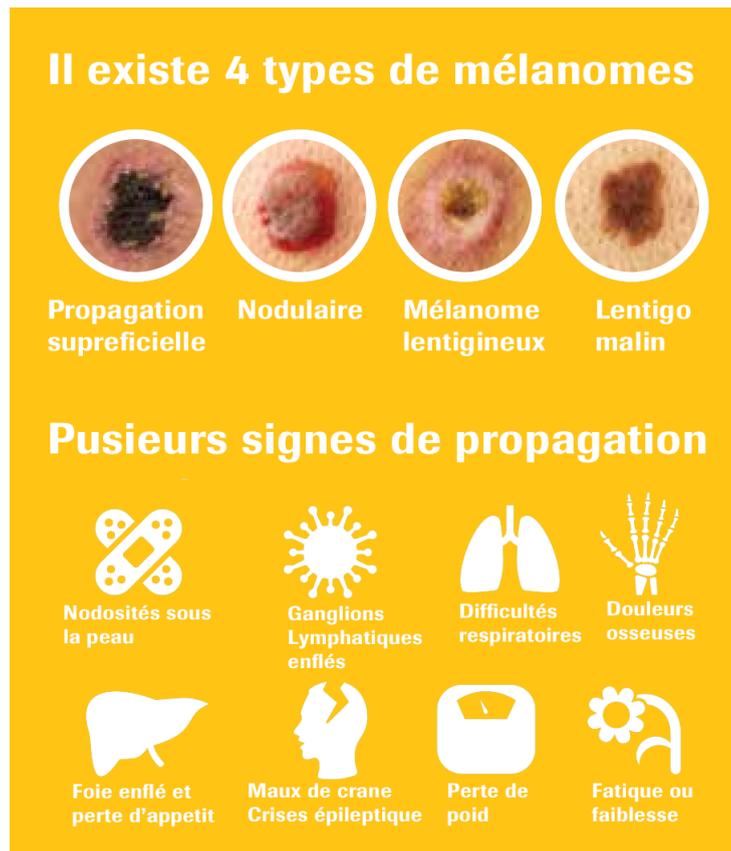


FIGURE 2.2 – Types de mélanomes et indices de propagation. [45]

## 2.5 Les statistiques sur le mélanome

Au cours de la dernière décennie (2013-2023), le nombre de nouveaux cas de mélanome invasif diagnostiqués chaque année a augmenté de 27 pourcents. Une personne meurt du mélanome chaque heure, chaque jour. Le risque de mélanome est plus élevé chez les individus ayant des parents, frères, sœurs ou enfants atteints de la maladie, avec environ 10% des patients atteints de mélanome ayant des antécédents familiaux. Il est important de noter que le mélanome est plus de 20 fois plus fréquent chez les personnes de race blanche que chez les personnes de race noire, avec un risque tout au long de la vie d'environ 2,5% (1 sur 40) pour les individus blancs, 0,1% (1 sur 1 000) pour les individus noirs et 0,5% (1 sur 200) pour les individus hispaniques.

En 2023, on estime que 97 610 personnes aux États-Unis recevront un diagnostic de nouveaux cas de mélanome, dont environ 58 120 hommes et 39 490 femmes. Lorsqu'on considère les cancers liés à l'âge, le mélanome occupe la troisième place parmi les cancers les plus fréquemment diagnostiqués chez les individus âgés de 25 à 39 ans aux États-Unis, et le neuvième chez les jeunes de 15 à 29 ans. Il est important de souligner que le risque de mélanome augmente avec l'âge, avec un âge moyen de diagnostic de 65 ans. Cependant, le mélanome n'est pas rare même chez les personnes de moins de 30 ans, étant l'un des cancers les plus courants chez les jeunes adultes, en particulier chez les jeunes femmes.[4]

Les statistiques de la figure 1 [2] confirment que la probabilité de développer un mélanome est plus élevée chez les hommes que chez les femmes. Une détection précoce précise et fiable du mélanome est essentielle, car elle peut considérablement améliorer les chances de survie. En effet, les lésions détectées précocement ont un taux de survie pouvant atteindre 90,0 %.

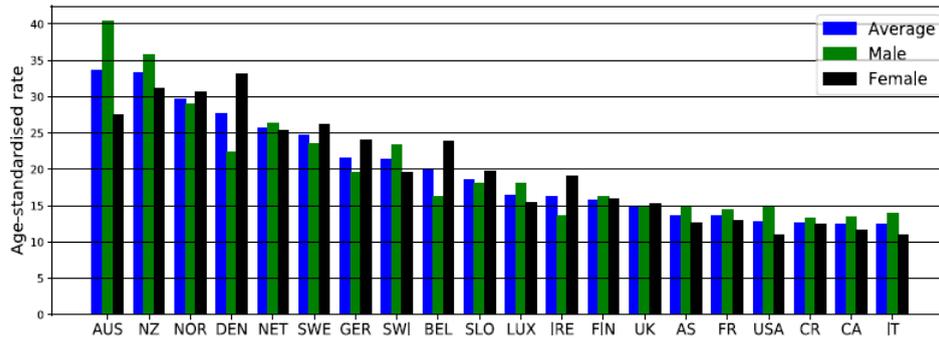


FIGURE 2.3 – Taux standardisés par âge du mélanome en 2018 dans les 20

pays les plus touchés. ( Les barres de gauche à droite représentent les cas de mélanome décroissants pour les pays tels que l’Australie (AUS), la Nouvelle-Zélande (NZ), la Norvège (NOR), le Danemark (DEN), les Pays-Bas (NET), la Suède (SWE), l’Allemagne (GER), la Suisse (SWI), la Belgique (BEL), la Slovénie (SLO), le Luxembourg (LUX), l’Irlande (IRE), la Finlande (FIN), le Royaume-Uni (UK), l’Autriche (AS), la France (FR), les États-Unis d’Amérique (USA), la République tchèque (CR), le Canada (CA) et l’Italie (IT) ) [2]

## 2.6 Les signes et les symptômes du mélanome

Les signes et symptômes sont des manifestations vitales permettant de détecter et de diagnostiquer diverses maladies et troubles. Dans le cas du mélanome, une forme grave de cancer de la peau, ces indicateurs jouent un rôle crucial pour un diagnostic et un traitement précoces. Il est essentiel de reconnaître les signes qui devraient alerter une personne quant à la possibilité d’avoir un mélanome. Les symptômes se manifestent comme suit :

Sur les zones du corps, qu’elles soient exposées au soleil ou protégées, il est conseillé d’examiner toute modification, nouveauté ou caractéristique inhabituelle. Il est à noter que, dans 20 à 30 % des cas, les mélanomes se développent à partir d’un grain de beauté. Dans ce cas, le grain de beauté change de taille ou de couleur, ses bords deviennent irréguliers. Parfois, il prend plusieurs couleurs, par exemple, brun, rouge ou bleu-noirâtre, et saigne. Dans 70 à 80 % des cas, les mélanomes se présentent sous la forme de taches qui ressemblent à un grain de beauté, d’apparition récente et de couleur noirâtre. En général, les mélanomes ne provoquent ni démangeaisons, ni saignements, ni douleur. [11]

Les mélanomes peuvent être présents sur l’ensemble du corps, mais ils sont plus fréquents dans le dos (chez les hommes) et sur le bas des jambes (chez les femmes). Ils peuvent également apparaître sur les muqueuses de la bouche, du nez ou des organes génitaux. Au niveau des ongles, ils se présentent généralement sous la forme d’une bande noire dans le sens de la longueur de l’ongle qui s’élargit au fil des mois. [11]

## 2.7 Comment évolue le mélanome ?

Les mélanomes naissent de quelques cellules cancéreuses qui apparaissent à la surface de la peau sous l'influence des rayons ultraviolets. Ensuite, ces cellules se multiplient, le plus souvent en surface, ce qui provoque un élargissement de la lésion. Après quelques années, les cellules cancéreuses évoluent et se mettent à envahir rapidement les couches profondes de la peau : le mélanome devient invasif. [11]

Lorsque le mélanome est invasif et en l'absence de traitement, les cellules cancéreuses vont progressivement migrer, via la circulation de la lymphe, dans les ganglions lymphatiques qui drainent la région du corps où se trouve la tumeur (ganglions du cou, des clavicules, des aisselles, des genoux, etc). Sans traitement, certaines de ces cellules vont ensuite passer dans la circulation sanguine pour aller s'installer et se multiplier dans le foie, les poumons, les os, le cerveau, etc. Ces tumeurs secondaires sont appelées « métastases ». [11]

## 2.8 Stades et Traitements du Mélanome

Le mélanome est un type de cancer de la peau qui se développe à partir des mélanocytes, les cellules qui produisent le pigment appelé mélanine. Le mélanome peut se former sur n'importe quelle partie du corps, mais il est plus fréquent sur les zones exposées au soleil, comme le visage, le dos, les bras et les jambes.[8] [9] [10]

Pour déterminer le stade du mélanome, les médecins utilisent un système appelé TNM, qui se base sur trois critères :

- T : la taille et l'épaisseur de la tumeur primaire, ainsi que son ulcération (rupture de la peau au-dessus de la tumeur).
- N : le nombre et l'emplacement des ganglions lymphatiques atteints par le cancer.
- M : la présence ou non de métastases (propagation du cancer à d'autres organes). [8] [9] [10] [12]

En fonction de ces critères, le mélanome est classé en 5 stades, allant de 0 à IV. Voici une description simplifiée de chaque stade, accompagnée de son propre traitement spécifique :

### Mélanomes précoces

- Stade 0 : le mélanome est limité à la couche la plus superficielle de la peau (l'épiderme) et n'a pas pénétré dans les couches plus profondes (le derme et l'hypoderme). Il n'y a pas d'ulcération ni d'atteinte des ganglions lymphatiques ou d'autres organes. Le pronostic est très bon, car le mélanome peut être enlevé chirurgicalement sans risque de récurrence. [8] [9] [12]
- Stade I : le mélanome a pénétré dans le derme, mais il est encore peu épais (moins de 2 mm) et il n'y a pas d'ulcération ni d'atteinte des ganglions lymphatiques ou d'autres organes. Le pronostic est bon, car le mélanome peut être enlevé chirurgicalement avec une marge de sécurité. Le risque de récurrence est faible, mais il faut surveiller régulièrement la peau et les ganglions lymphatiques. [8] [9] [10] [12]

**Mélanomes à risque intermédiaire ou élevé ( locorégional )**

- Stade II : le mélanome est plus épais (plus de 2 mm) ou il y a une ulcération, mais il n’y a pas d’atteinte des ganglions lymphatiques ou d’autres organes. Le pronostic est moins bon, car le mélanome a plus de chances de se propager. Il faut enlever chirurgicalement le mélanome avec une large marge de sécurité et parfois faire une biopsie du ganglion sentinelle, qui est le premier ganglion lymphatique susceptible d’être atteint par le cancer. Le risque de récurrence est plus élevé, et il faut faire un suivi régulier avec des examens complémentaires (prises de sang, échographies, scanners...). [8] [9] [10] [11]

**Mélanomes avancés ( métastatique )**

- Stade III : le mélanome s’est propagé aux ganglions lymphatiques proches de la tumeur primaire, mais pas à d’autres organes. Le pronostic est mauvais, car le mélanome est très agressif. Il faut enlever chirurgicalement le mélanome et les ganglions lymphatiques atteints, et parfois faire une chimiothérapie, une immunothérapie ou une radiothérapie pour réduire le risque de récurrence. Le suivi doit être fréquent et rigoureux. [8] [9] [10] [11]
- Stade IV : le mélanome s’est propagé à d’autres organes, comme les poumons, le foie, le cerveau ou les os. Le pronostic est très mauvais, car le mélanome est incurable à ce stade. Il faut traiter les symptômes et essayer de ralentir la progression du cancer avec des traitements palliatifs, comme la chimiothérapie, l’immunothérapie ou la radiothérapie. Les métastases osseuses sont traitées par chirurgie, radiothérapie, et chimiothérapie contre les métastases du foie, du poumon ou du cerveau. Le suivi doit être adapté à l’état du patient. [8] [9] [10] [11]

## Les stades du mélanome

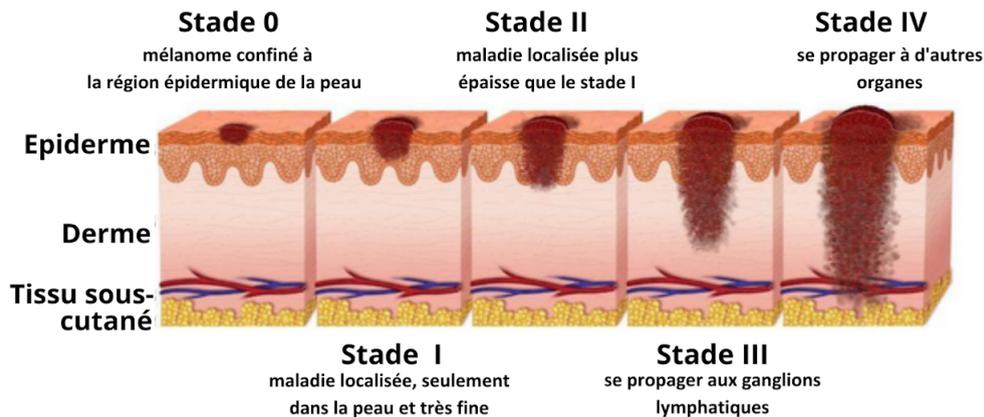


FIGURE 2.4 – Les stades de melanome.[5]

## 2.9 L'importance de la détection précoce du mélanome pour la santé

La détection précoce du mélanome est cruciale pour la santé car elle peut améliorer considérablement les chances de guérison. Le mélanome est un type de cancer de la peau qui peut se propager rapidement à d'autres parties du corps, ce qui peut rendre le traitement plus difficile et moins efficace. Cependant, lorsqu'il est détecté tôt, le mélanome peut être traité avec succès par l'ablation chirurgicale de la lésion, avant qu'elle ne se propage à d'autres parties du corps. Cela peut sauver des vies et réduire la nécessité de traitements plus invasifs tels que la chimiothérapie ou la radiothérapie. Par conséquent, il est important de prendre au sérieux toute lésion cutanée suspecte et de se faire examiner par un professionnel de la santé qualifié dès que possible.

## 2.10 Approches d'analyse des images dermoscopiques

Il est recommandé à tout le monde de surveiller régulièrement ses grains de beauté afin de détecter tout signe de transformation ou de développement de mélanome. À cet effet, nous présentons plusieurs méthodes :

### 2.10.1 Méthode de la règle ABCD

[Stolz 1994] a introduit avec son équipe un nouvel algorithme basé sur une analyse multivariée. Il utilise 4 critères différents. Le critère A repose sur l'asymétrie qui comprend l'asymétrie de formes mais aussi l'asymétrie de textures et de couleurs. Le critère B qui repose sur les bords abrupts des structures pigmentées. Le critère C qui repose sur la diversité des couleurs, et le critère D qui repose sur les différentes structures dermoscopiques.

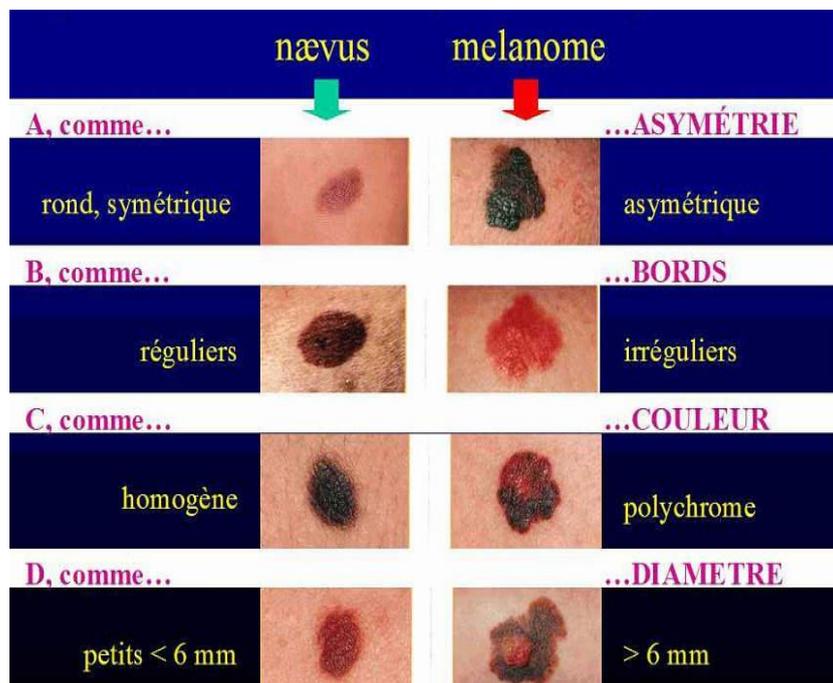


FIGURE 2.5 – Application de la règle ABCD sur une tâche Naevus pigmentaire et un mélanome. [6]

### 2.10.2 Méthode de la règle ABCD-E

[Kittler, 1999] a introduit un nouveau critère, le critère E pour Évolution, qui prend en compte les informations relatives aux changements morphologiques récents observés et signalés par le patient concernant la lésion.

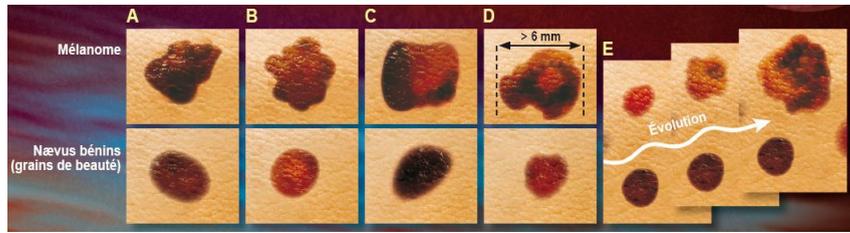


FIGURE 2.6 – Application de la règle ABCD-E. [7]

### 2.10.3 Méthode des 7 points de la liste de contrôle

Cette méthode repose sur 7 critères répartis en deux catégories, les critères majoritaires : la présence ou non de réseaux pigmentaires atypiques, de voiles bleu-blanc et de motifs vasculaires atypiques et les critères minoritaires : la présence ou non de stries irrégulières, de pigmentations irrégulières, de points/globule irréguliers et de structure de régression. Un score est un coefficient de deux points entre les 2 critères. Si le score est supérieur ou égale à 3 alors la lésion sera considérée comme maligne, et bénigne dans le cas contraire.[Dal Pozzo, 1997]. [3]

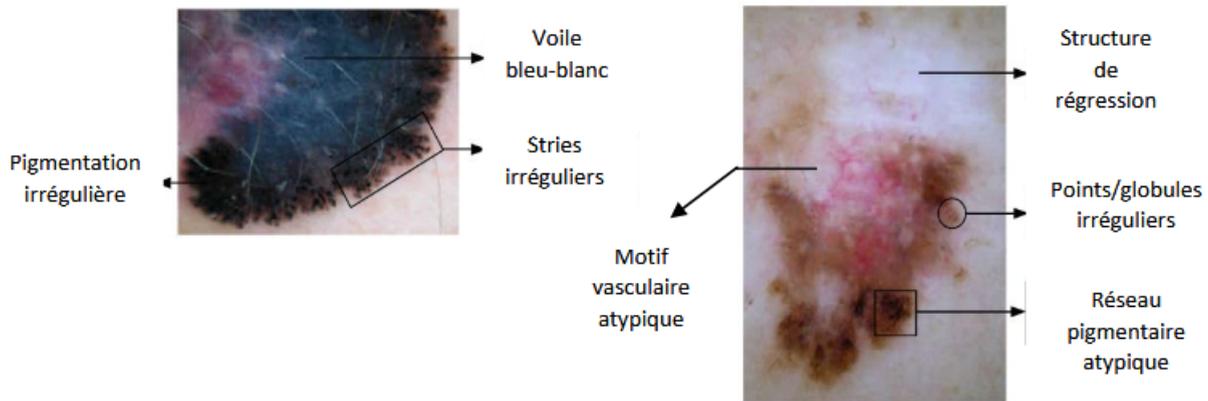


FIGURE 2.7 – Examen dermoscopique. Illustration des critères utilisés dans la méthode des 7 points de la liste de contrôle. [3]

### 2.10.4 Méthode de Menzies

La présence d'une ou plusieurs classes de couleurs indique que la lésion doit être considérée comme un mélanome potentiel. Dans la série originale, il avait une sensibilité de 92% et une spécificité de 71% pour le diagnostic du mélanome. Il a été démontré que cet algorithme permet aux médecins de soins primaires d'augmenter leur sensibilité pour le diagnostic du mélanome de 38% par rapport à la visualisation clinique standard.[Menzies 2001]

### 2.10.5 Méthode d'analyse de motifs

Le médecin doit d'abord déterminer si la lésion cutanée pigmentée est mélanocytaire ou non mélanocytaire. La présence de réseau pigmenté, de globules ou de points caractérise les lésions mélanocytaires. Les lésions mélanocytaires sont identifiées par leurs caractéristiques dermoscopiques générales (le nævus bleu a une zone bleu-grisâtre homogène qui détermine son diagnostic). Si la lésion ne présente aucune des caractéristiques dermatoscopiques, il s'agit d'une lésion non-mélanocytaire [Perhambberger et al, 1987]. Les méthodes d'analyse suivent soit une approche classique ou moderne.

## 2.11 Application des techniques de l'intelligence artificielle dans le diagnostic médical

### 2.11.1 Contexte et importance de l'intelligence artificielle dans le domaine médical

L'intelligence artificielle (IA) est un domaine de recherche en pleine expansion et promis à un grand avenir. L'IA peut être retrouvée dans plusieurs domaines dont : L'automobile (voiture autonome), la médecine, l'industrie, le marketing, l'éducation et bien plus encore. Ses applications, qui concernent toutes les activités humaines, permettent notamment d'améliorer la qualité des soins.[13] Les organisations de santé utilisent des solutions d'IA pour éclairer leurs décisions et améliorer les expériences d'utilisation des données.[14] Selon de nouvelles orientations publiées par l'organisation mondiale de la santé (OMS), l'intelligence artificielle (IA) constitue un grand espoir pour améliorer la prestation des soins et la médecine dans le monde entier, mais à condition de placer l'éthique et les droits humains au cœur de sa conception, de son déploiement et de son utilisation. [15]

Parmi les techniques d'application de l'IA, on trouve le machine learning, qui est une branche de l'IA qui consiste à apprendre à partir de données et à améliorer ses performances dans l'exécution d'une tâche spécifique. Le machine learning peut aider à prévenir, à diagnostiquer et à traiter des maladies telles que le mélanome, qui est un type de cancer de la peau très agressif et potentiellement mortel. Le diagnostic précoce du mélanome est essentiel pour augmenter les chances de survie des patients. Le machine learning peut apporter une aide précieuse pour le diagnostic précoce du mélanome en analysant des images dermoscopiques de grains de beauté et en détectant les signes de malignité. Dans ce travail, nous allons nous concentrer sur les techniques de machine learning qui peuvent être utilisées pour la détection et la classification du mélanome à partir d'images dermoscopiques.

### 2.11.2 Techniques de l'apprentissage automatique pour la classification et la prédiction du mélanome

L'intelligence artificielle (IA) est de plus en plus utilisée en dermatologie, notamment pour le mélanome, car elle permet d'analyser les images de la peau et de détecter les signes de malignité. L'apprentissage automatique (machine learning) et l'apprentissage profond (deep learning) sont des techniques d'IA qui permettent aux systèmes d'apprendre à partir de données et de s'améliorer au fil du temps. Dans ce qui suit, nous allons définir quelques concepts liés au machine learning.

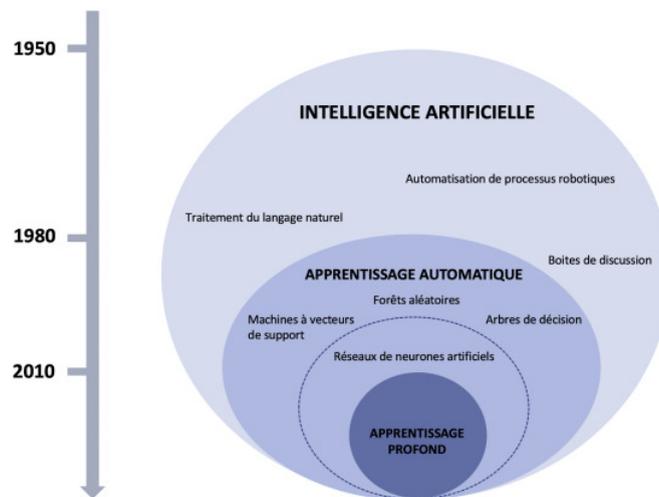


FIGURE 2.8 – Un aperçu historique des avancées en Intelligence Artificielle et en Apprentissage Automatique (IA et ML). [24]

### 2.11.3 Machine Learning

Le machine learning, ou apprentissage automatique, est une branche de l'intelligence artificielle qui vise à créer des systèmes capables d'apprendre à partir de données et de s'améliorer avec l'expérience, sans être explicitement programmés pour le faire. Le machine learning permet aux machines de réaliser des tâches ou de faire des prédictions en se basant sur des modèles mathématiques ou statistiques, construits à partir de données d'entraînement. Le machine learning est utilisé dans de nombreux domaines, tels que la reconnaissance d'images, la traduction automatique, la conduite autonome, la recommandation de produits, le diagnostic médical, etc. [16]

### 2.11.4 Types d'algorithmes du Machine Learning

Il existe différents types d'algorithmes de machine learning, selon la méthode employée pour traiter les données et le type de problème à résoudre. On distingue principalement trois grandes catégories : l'apprentissage supervisé, l'apprentissage non supervisé et l'apprentissage par renforcement.

### 2.11.5 Apprentissage supervisé

L'apprentissage supervisé consiste à entraîner un algorithme à partir de données étiquetées, c'est-à-dire dont le résultat attendu est connu. L'objectif est que l'algorithme puisse ensuite prédire le résultat pour de nouvelles données non étiquetées. Par exemple, on peut entraîner un algorithme à reconnaître des fruits à partir d'images étiquetées avec le nom du fruit. L'apprentissage supervisé peut être utilisé pour des problèmes de classification (attribuer une catégorie à une donnée) ou de régression (prédire une valeur numérique). [17]

### 2.11.6 Apprentissage non supervisé

L'apprentissage non supervisé consiste à laisser un algorithme découvrir les structures et les patterns cachés dans des données non étiquetées, sans lui fournir de résultat attendu. L'objectif est que l'algorithme puisse ensuite regrouper ou séparer les données selon des critères qu'il a

appris. Par exemple, on peut laisser un algorithme trouver des similitudes entre des clients à partir de leurs données comportementales. L'apprentissage non supervisé peut être utilisé pour des problèmes de clustering (regroupement) ou de réduction de dimensionnalité (simplification des données). [17]

### 2.11.7 Apprentissage par renforcement

L'apprentissage par renforcement consiste à entraîner un algorithme à partir d'un système de récompense et de pénalité, en fonction des actions qu'il réalise dans un environnement donné. L'objectif est que l'algorithme puisse ensuite optimiser son comportement pour maximiser sa récompense. Par exemple, on peut entraîner un algorithme à jouer à un jeu vidéo en lui donnant des points positifs ou négatifs selon ses performances. [18] L'apprentissage par renforcement est inspiré du comportement des animaux qui apprennent par essai-erreur et par renforcement positif ou négatif. L'apprentissage par renforcement est utilisé dans de nombreux domaines, comme la robotique, les jeux, la chimie ou l'optimisation. [19]

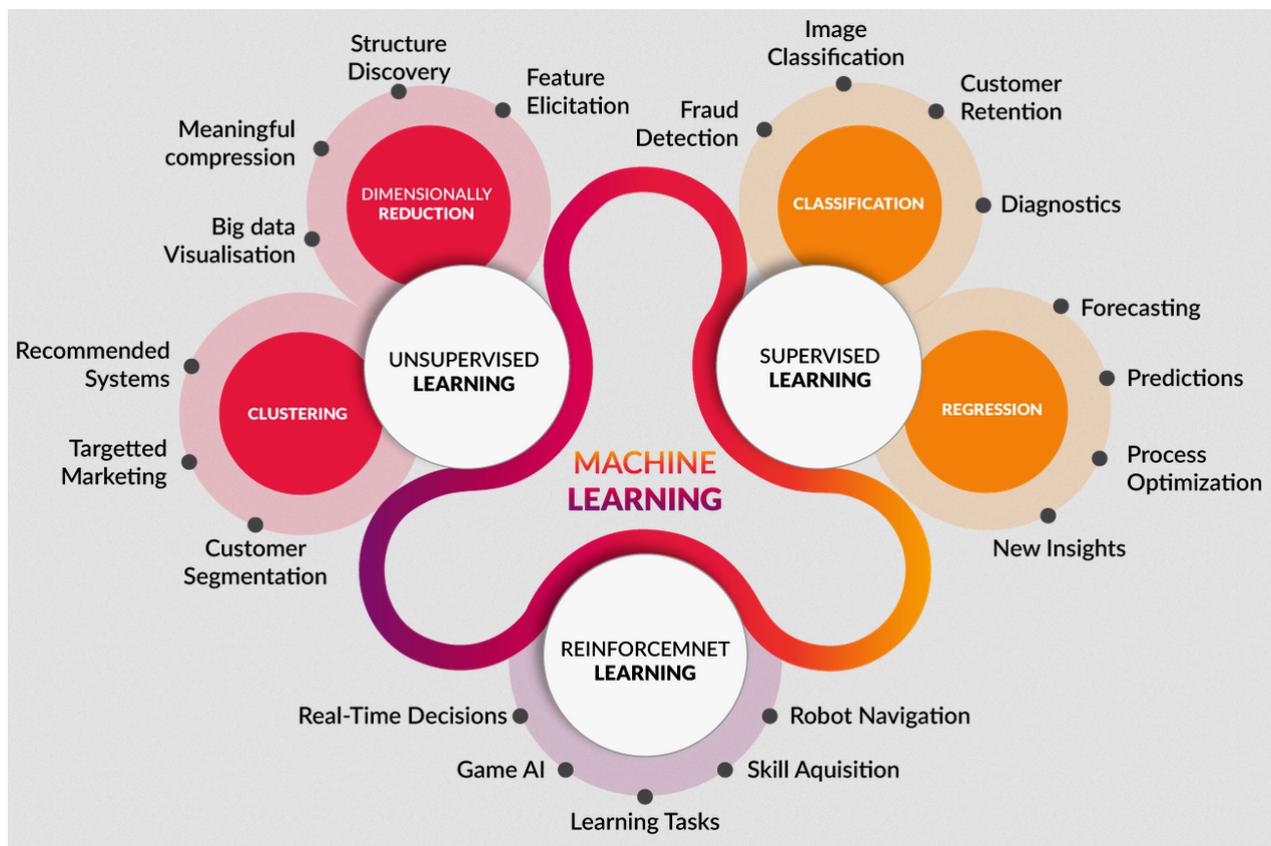


FIGURE 2.9 – Types des algorithmes de machine learning. [47]

### 2.11.8 Deep Learning

Le deep learning, ou apprentissage profond, est une branche du machine learning qui utilise des réseaux de neurones artificiels pour apprendre à partir de données et réaliser des tâches complexes. Les réseaux de neurones artificiels sont des modèles informatiques inspirés du fonctionnement du cerveau humain, composés d'unités de calcul appelées neurones, reliées

entre elles par des connexions pondérées. Le deep learning se caractérise par l'utilisation de réseaux de neurones profonds, c'est-à-dire comportant plusieurs couches cachées entre la couche d'entrée et la couche de sortie. Chaque couche effectue une transformation non linéaire des données provenant de la couche précédente, permettant ainsi d'extraire des caractéristiques de plus en plus abstraites et pertinentes pour la tâche à accomplir. Le deep learning repose sur des algorithmes d'apprentissage qui ajustent les poids des connexions en fonction des données d'entraînement et du résultat attendu, afin de minimiser une fonction d'erreur. [20] [21]

### 2.11.9 Types d'algorithmes du Deep Learning

Il existe différents types de réseaux de neurones profonds, selon la structure, le mode d'apprentissage et le domaine d'application. Parmi les types les plus courants, on peut citer :

#### Le perceptron multicouche

Le perceptron multicouche (PMC), qui est le plus simple et le plus ancien. Il est constitué de couches successives. Une couche est un ensemble de neurones n'ayant pas de connexion entre eux. Une couche d'entrée lit les signaux entrants, un neurone par entrée  $x_j$ , une couche en sortie fournit la réponse du système. Dans un perceptron, un neurone d'une couche cachée est connecté en entrée à chacun des neurones de la couche précédente et en sortie à chaque neurone de la couche suivante. Il est utilisé pour des problèmes de classification ou de régression, en utilisant généralement un apprentissage supervisé. [25]

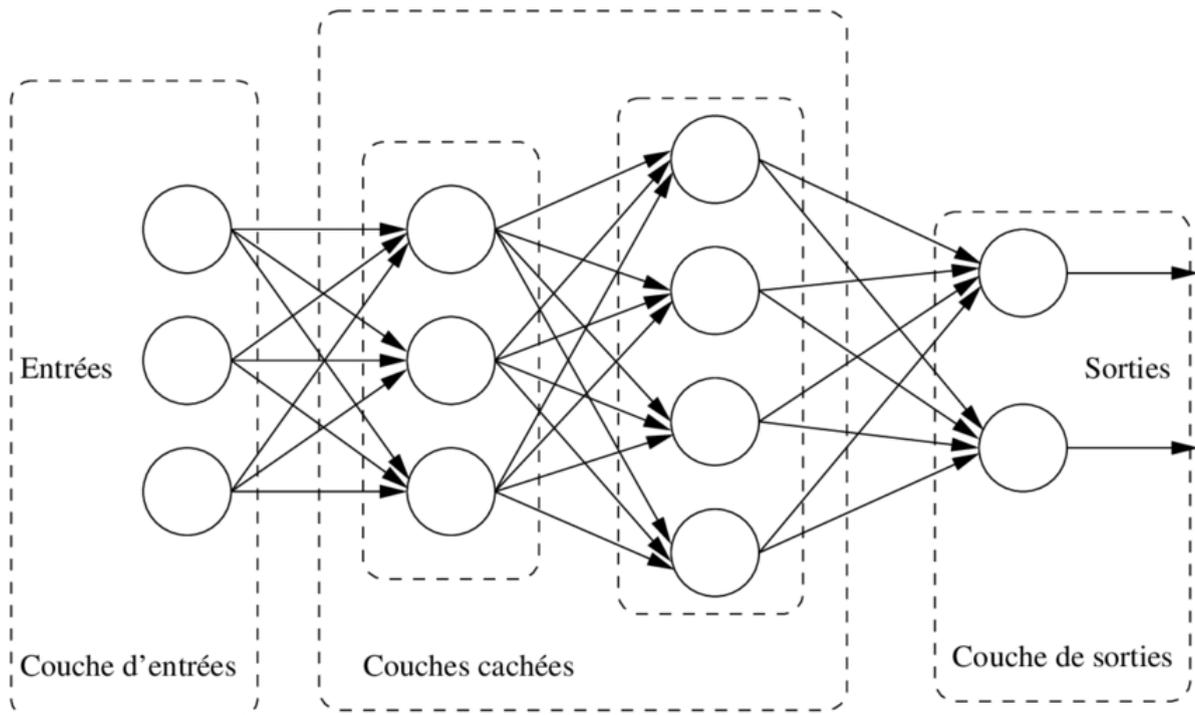


FIGURE 2.10 – Architecture d'un perceptron multicouche (PMC). [26]

Le perceptron multicouche (PMC) est constitué de plusieurs couches de neurones qui sont :

- **Couches d'entrées (Input Layer) :** La couche d'entrée est constituée d'un ensemble de neurones qui servent de point d'entrée pour les données. Chaque neurone dans cette couche représente une caractéristique ou une dimension des données initiales. C'est ici

que les signaux d'entrée sont introduits dans le réseau pour démarrer le processus de traitement. [27]

- **Couches cachées (Hidden Layers) :** Les couches cachées, généralement multiples et appelées couche cachée 1, couche cachée 2, etc., forment le cœur du réseau de neurones. C'est à ce niveau que les relations complexes et abstraites entre les variables sont mises en évidence. Chaque couche cachée consiste en un ensemble de neurones interconnectés qui traitent les signaux provenant des couches précédentes. Ces neurones apprennent à capturer des caractéristiques de plus en plus abstraites à mesure que l'information se propage à travers les couches cachées. [27]
- **Couches de sorties (Output Layer) :** La couche de sortie représente le résultat final du réseau de neurones, c'est-à-dire sa prédiction ou sa sortie. Le nombre de neurones dans cette couche dépend du type de tâche que le réseau effectue. Par exemple, dans la classification, chaque neurone peut correspondre à une classe différente, indiquant la probabilité que l'entrée appartienne à cette classe. Dans la régression, la couche de sortie peut représenter une valeur numérique. [27]
- **Les réseaux neuronaux convolutifs (CNN) :** Les réseaux neuronaux convolutifs (CNN), qui sont spécialement conçus pour traiter des données visuelles. Ils sont composés de couches convolutives, qui appliquent des filtres locaux sur les données d'entrée, permettant ainsi de détecter des motifs visuels à différentes échelles et positions. Ils sont également composés de couches de pooling, qui réduisent la taille des données en conservant les informations essentielles. Ils sont utilisés pour des problèmes de reconnaissance d'images, de segmentation, de détection d'objets et de traitement d'images médicales etc. [28]

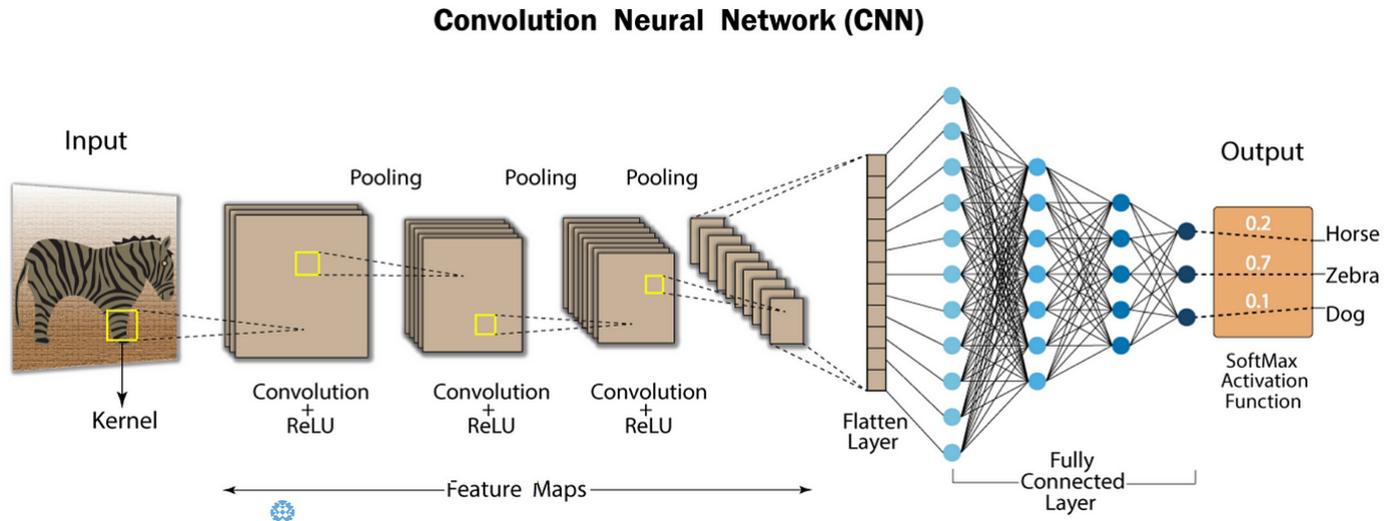


FIGURE 2.11 – CNN : le voyage d'une image à travers des couches neuronales. [46]

Les réseaux de neurones convolutifs (CNN) sont composés de plusieurs types de couches. Voici les différents types de couches d'un CNN :

- **Couches de convolution :** Les couches de convolution sont des composants clés des réseaux de neurones convolutifs (CNN), qui permettent de détecter les caractéristiques de l'image en appliquant des filtres à convolution sur l'image d'entrée. Chaque filtre produit une carte de caractéristiques qui est ensuite utilisée par les couches suivantes. [29]

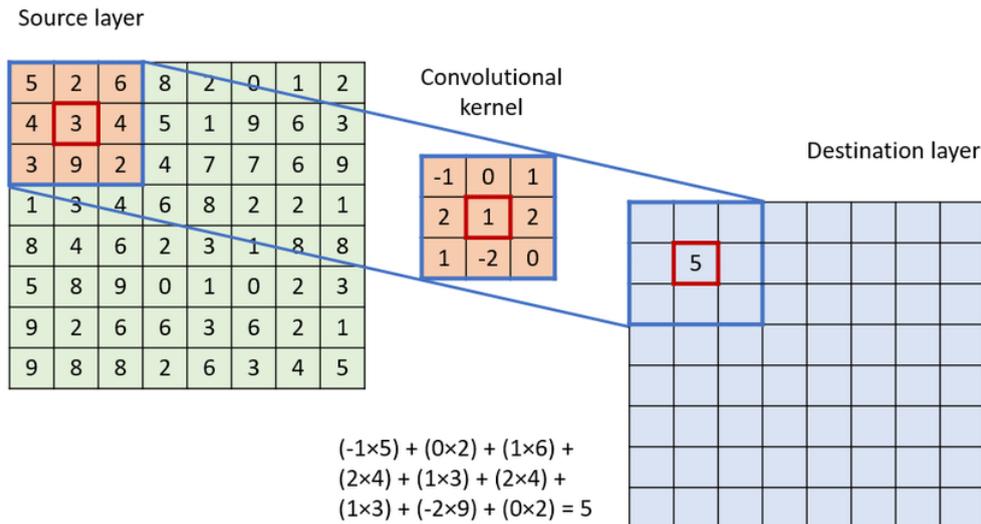


FIGURE 2.12 – Illustration schématique d’une opération de convolution. ( Mise en évidence de l’extraction des caractéristiques spatiales à travers le décalage du noyau de convolution.) [30]

- **Couches de pooling** Cette couche est souvent placée entre deux couches de convolution. Elle permet de réduire la taille des images tout en préservant leurs caractéristiques importantes. L’opération de pooling consiste à prendre la valeur maximale ou moyenne d’une région de l’image. Cela permet de réduire le nombre de paramètres du réseau, d’éviter le surapprentissage et de rendre le réseau plus robuste aux variations locales. [29]

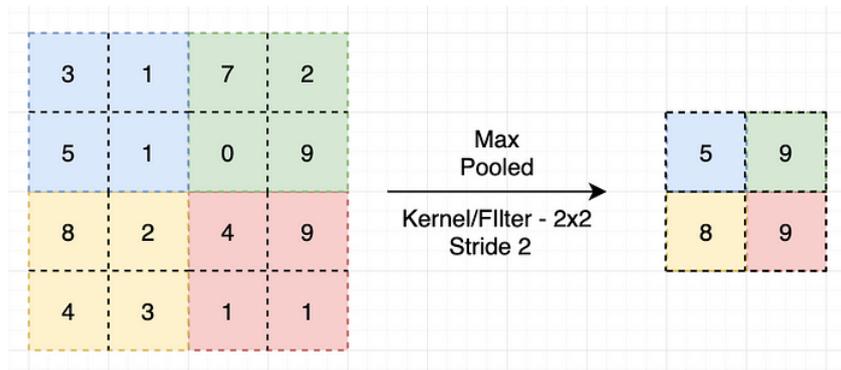


FIGURE 2.13 – Représentation schématique d’une opération de pooling. ( Mise en évidence du processus de réduction des dimensions et de préservation des caractéristiques clés.) [31]

- **Couches fully-connected (FC)** La couche de fully connected (en anglais fully connected layer) (FC) s’applique sur une entrée préalablement aplatie où chaque entrée est connectée à tous les neurones. Les couches de fully connected sont typiquement présentes à la fin des architectures de CNN et elle permet de classifier l’image en produisant une sortie qui correspond à la probabilité de chaque classe. [32]

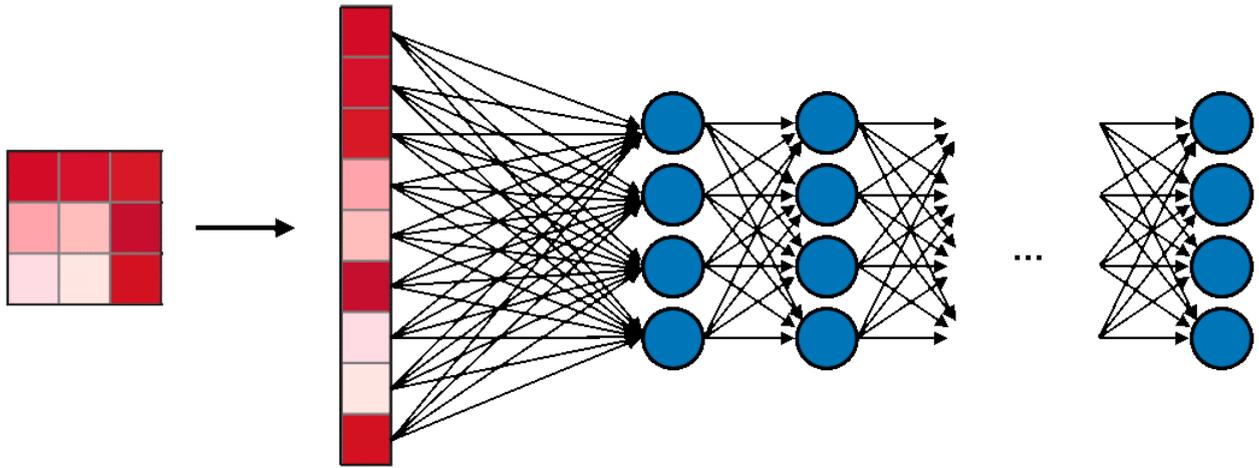


FIGURE 2.14 – Étapes du Pooling au Flattening vers une Couche Entièrement Connectée [32]

Il est courant d’avoir plusieurs couches de convolution suivies de couches ReLU et de pooling en séquence, formant ainsi un bloc. Ces blocs peuvent être répétés plusieurs fois dans un CNN. Cependant, il n’est pas courant de placer plusieurs couches de pooling consécutives sans une couche de convolution entre elles. Placer plusieurs couches de pooling consécutives réduirait rapidement la dimensionnalité des données, ce qui pourrait entraîner une perte d’informations importantes. [33]

- **Flatten** : Le Flattenning est une méthode qui consiste à aplatir la matrice obtenue après le Pooling, dans le but de placer les données à l’entrée du futur réseau pour la classification comme montrée à la figure 2.15 précédente. [34]

### Exploration des Variétés de Réseaux de Neurones

En explorant les multiples facettes du domaine du Deep Learning, on découvre une richesse d’algorithmes puissants pour répondre à diverses tâches comme le montre la figure 2.24. Parmi ces approches, les Réseaux de Neurones Récurrents (RNN) se distinguent en particulier pour leur aptitude à traiter des données séquentielles, ce qui les rend inestimables pour la prédiction de séries chronologiques et le traitement de données textuelles. Par exemple, les RNN peuvent être utilisés pour prédire les prix des actions en fonction des données historiques ou pour générer du texte en continuant une phrase donnée.

Les Autoencodeurs, pour leur part, excellent dans la création de nouvelles données en apprenant des représentations condensées des entrées. Par exemple, ils peuvent être utilisés pour la compression de données, la réduction de bruit ou la génération d’images.

Les Réseaux de Neurones Croyants (DBN) excellent dans la modélisation des relations probabilistes entre les données. Par exemple, ils peuvent être utilisés pour la détection d’anomalies ou la recommandation de produits.

Cependant, dans cette étude, notre attention se focalise exclusivement sur les Réseaux de Neurones Convolutifs (CNN). Ce choix est guidé par la nature des données que nous manipulons, essentiellement des images. Les CNN s’établissent comme le choix de prédilection pour de tels problèmes de classification d’images, grâce à leur capacité à saisir les caractéristiques spatiales inhérentes aux images.

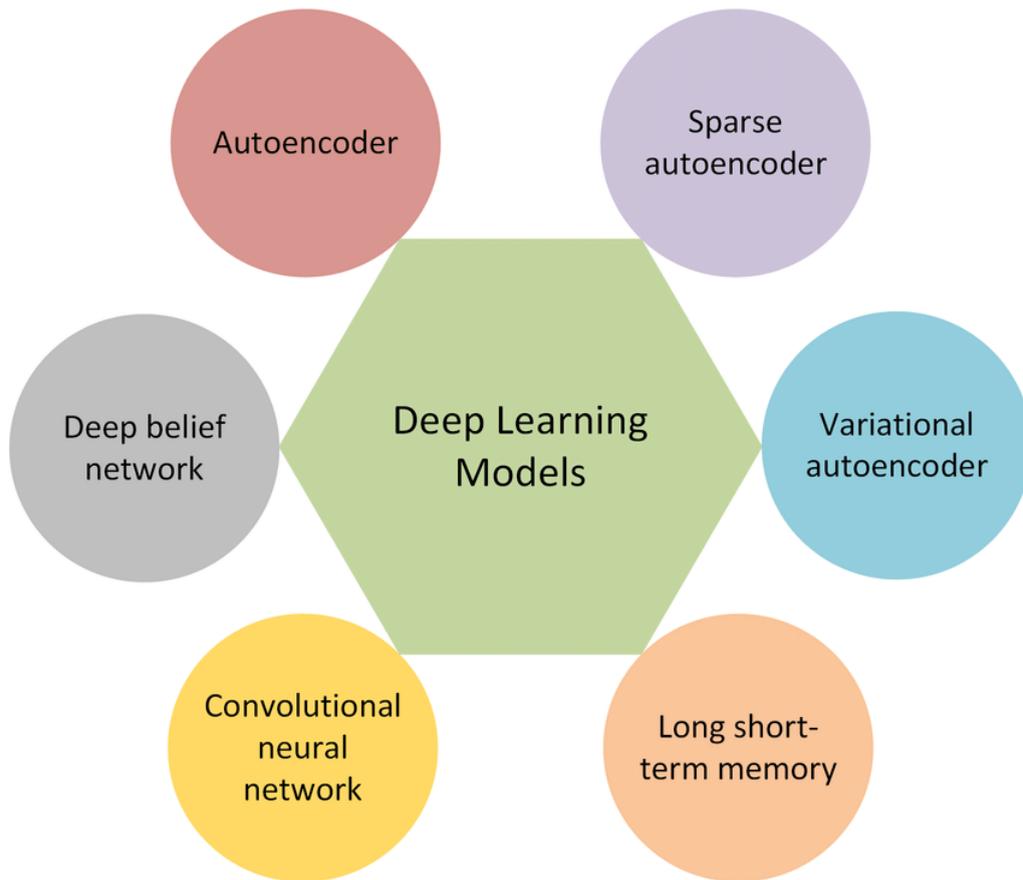


FIGURE 2.15 – Types de réseaux de neurones en Deep Learning. [35]

### 2.11.10 Sur apprentissage et Sous apprentissage

L'Overfitting (sur-apprentissage), et l'Underfitting (sous-apprentissage) sont les causes principales des mauvaises performances des modèles prédictifs générés par les algorithmes de Machine Learning. Dans cette section on verra ce que veut dire ces deux termes.

- **Sur apprentissage** : Cela représente un modèle qui a appris par cœur ses données d'entraînement, qui fonctionne donc bien sur le jeu d'entraînement mais pas de validation. Il effectue alors de mauvaises prédictions sur de nouvelles, car elles ne sont pas exactement les mêmes que celles du jeu d'entraînement. Pour y remédier, il faut améliorer la flexibilité du modèle, et donc jouer sur des concepts de régularisation par exemple, ou encore d'early stopping. [101]
- **Sous apprentissage** : Ce cas-ci représente un modèle qui n'arrive pas à déduire des informations du jeu de données. Il n'apprend donc pas assez et réalise de mauvaises prédictions sur le jeu d'entraînement. Il faut donc complexifier le réseau, car il ne taille pas bien par rapport aux types de données d'entrées. En effet, il n'arrive pas à capter la relation entre les données d'entrées et leur label. [101]

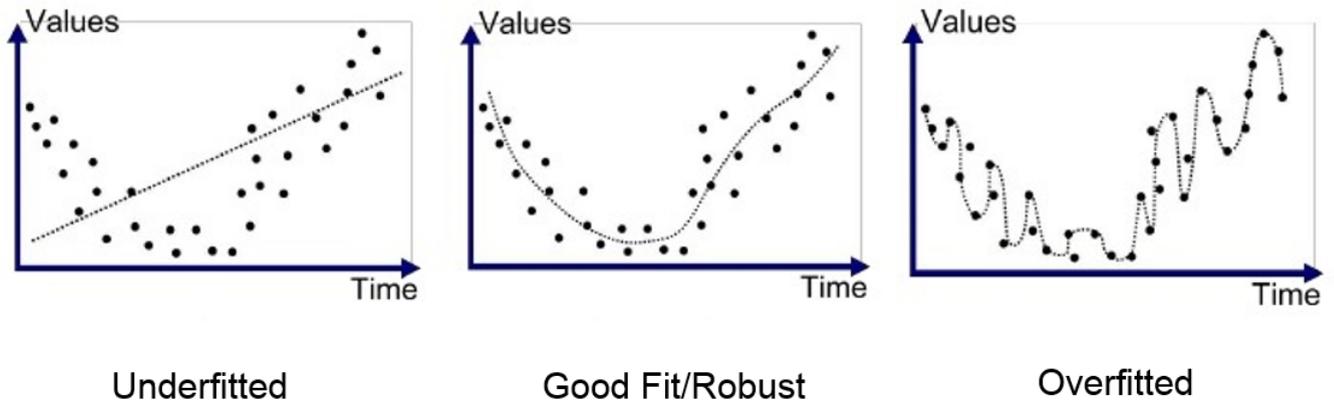


FIGURE 2.16 – Overfitting et underfitting. [102]

### 2.11.11 Différence entre le Machine Learning et le Deep Learning

Le deep learning se distingue du machine learning classique par sa capacité à apprendre des représentations complexes et hiérarchiques des données, sans avoir besoin d’une intervention humaine pour définir les caractéristiques pertinentes. Le deep learning permet ainsi de résoudre des problèmes plus difficiles et plus variés que le machine learning classique, tels que la reconnaissance d’images, la synthèse vocale, la traduction automatique ou la génération de texte. [22]

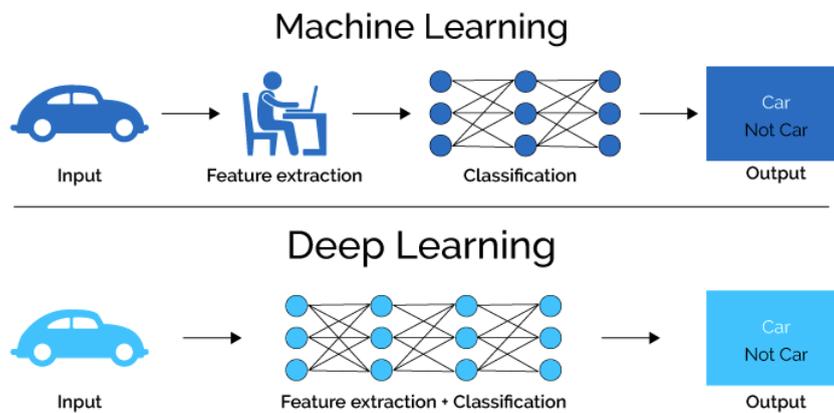


FIGURE 2.17 – Différence entre le Machine Learning et le Deep Learning. [23]

Le tableau ci-dessus illustre en détail les différences entre le machine learning et le deep learning :

Spécificités	Deep Learning	Machine Learning
Mode d'organisation des informations	Données non structurées	Données structurées
Base de données	Supérieure à 1 millions de données	Limitée ou contrôlable
Type d'entraînement	Méthode d'apprentissage autonome	Entraînement par l'humain obligatoire
Algorithme	Réseau de neurones	Algorithme modifiable
Domaines d'application	Tâches complexes (cybersécurité, assistant vocal, création de contenu...)	Actions routinières simples (marketing en ligne, chatbot, vente...)

TABLE 2.1 – Tableau comparatif entre le Machine Learning et le Deep Learning. [28]

### 2.11.12 Les fonctions d'activations usuelles

Les fonctions d'activation comme dans le système biologique humain, où l'influx nerveux qui arrive dans un bouton synaptique avec une certaine valeur excite ou non le nerf. Cette excitation est équivalente à l'activation. Cette dernière correspond à une représentation de l'information en sortie afin de préciser la pertinence ou non de la structure étudiée. Les fonctions d'activation les plus utilisées sont élaborées dans les sous-sections de cette section. [34]

### 2.11.13 Fonction sigmoïde

La fonction Sigmoïde est la fonction d'activation utilisée en dernière couche d'un réseau de neurones construit pour effectuer une tâche de classification binaire. Cette fonction fournit un résultat compris entre 0 et 1. [34]

L'expression littérale de la fonction sigmoïde s'écrit comme suit :[37]

$$\text{Fonction : } \sigma(z) = \frac{1}{1 + e^{-z}}$$

$$\text{Dérivée : } \frac{d\sigma(z)}{dz} = \sigma(z)(1 - \sigma(z))$$

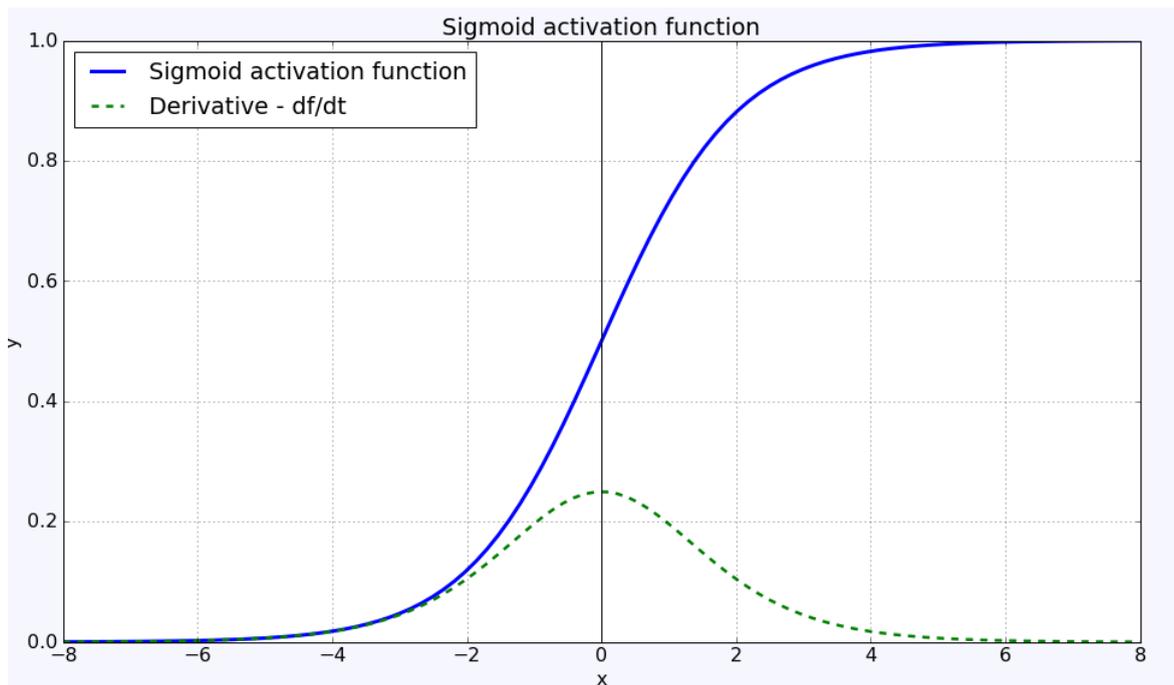


FIGURE 2.18 – Représentation graphique de la fonction sigmoïde et de sa dérivée. [36]

### 2.11.14 Fonction softmax

La fonction Softmax est la fonction d'activation utilisée en dernière couche d'un réseau de neurones construit pour effectuer une tâche de classification multi-classes. Pour chaque sortie, Softmax donne un résultat entre 0 et 1. De plus, si l'on additionne ces sorties entre elles, le résultat donne 1. [34] [38]

L'expression littérale de sa fonction s'écrit comme suit :[37]

Fonction	Dérivée partielle
$S_{\mu}(\vec{z}) = \frac{e^{z_{\mu}}}{\sum_{i=1}^N e^{z_i}}$ avec $\vec{z} = (z_1, z_2, \dots, z_{\mu}, \dots, z_N)$ et $\mu \in [1, N]$	$\frac{\partial S_{\mu}(\vec{z})}{\partial z_k} = S_{\mu}(\delta_{\mu k} - S_k)$ et $\delta_{kk} = 1, \delta_{\mu k} = 0$ (delta de Kronecker)

### 2.11.15 Fonction ReLu

ReLU est l'acronyme d'un terme anglicisme Rectified Linear Unit ou en français Unité Linéaire Rectifiée. Elle est l'une des fonctions les plus populaires de nos jours. Elle permet un entraînement plus rapide comparé aux fonctions sigmoïde et tanh, étant plus légère. Elle est réputée pour bien propager l'erreur en raison de sa pente de 1. Cependant, si son activation est toujours négative peu importe le vecteur d'entrée, le neurone sera alors « désactivé » ou « mort ». Ainsi, il y aura moins de neurones pour mettre à jour le réseau. Ainsi, il est souhaitable d'utiliser un grand nombre de neurones dans une couche avec la fonction d'activation ReLU. [34] [37] [38]

L'expression littérale de sa fonction s'écrit comme suit :

$$\text{Fonction : } \text{ReLU}(z) = \begin{cases} 0 & \text{si } z < 0 \\ z & \text{si } z \geq 0 \end{cases}$$

$$\text{ou bien } \text{ReLU}(z) = \max(0, z)$$

$$\text{Dérivée : } \frac{d\text{ReLU}(z)}{dz} = \begin{cases} 0 & \text{si } z < 0 \\ 1 & \text{si } z \geq 0 \end{cases}$$

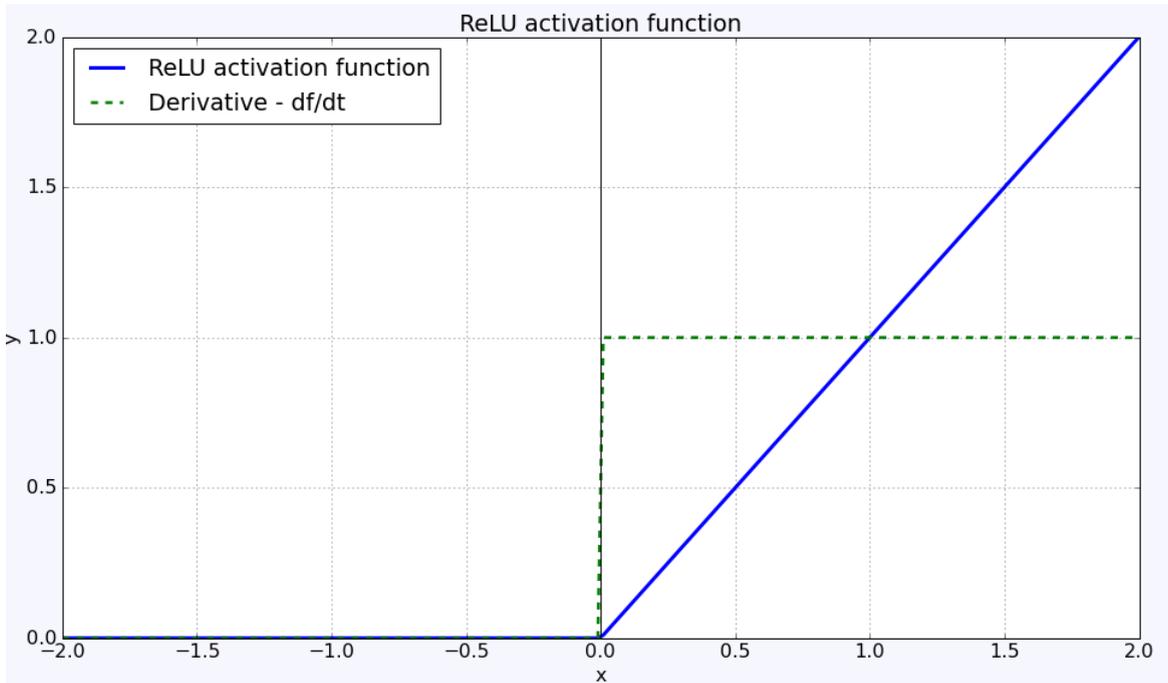


FIGURE 2.19 – Représentation graphique de la fonction ReLU et de sa dérivée. [36]

### 2.11.16 Fonction Leaky ReLU

La fonction Leaky ReLU est une amélioration de la fonction ReLU. La particularité réside dans sa légère inclinaison négative pour les valeurs inférieures à zéro. Cela introduit une variation pour les valeurs négatives, évitant ainsi l'inertie complète des neurones. Bien qu'ils puissent sembler plongés dans un état de sommeil prolongé, ils gardent toujours l'opportunité de se réactiver à tout moment. [34] [36]

L'expression littérale de la fonction sigmoïde s'écrit comme suit : [37]

$$\text{LReLU}(z) = \begin{cases} \varepsilon z & \text{si } z < 0 \\ z & \text{si } z \geq 0 \end{cases} \quad \text{ou bien} \quad \text{LReLU}(z) = \max(\varepsilon z, z)$$

avec  $\varepsilon \in [0,1[$ , mais traditionnellement  $\varepsilon = 0.1$

$$\frac{d\text{LReLU}(z)}{dz} = \begin{cases} \varepsilon & \text{si } z < 0 \\ 1 & \text{si } z \geq 0 \end{cases}$$

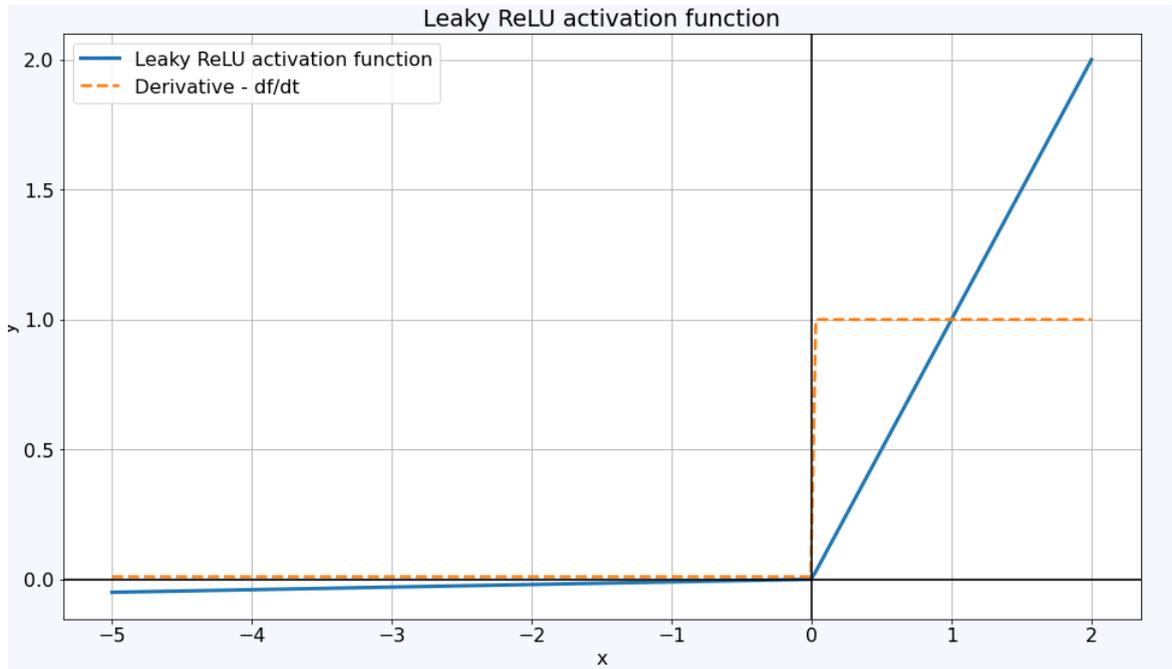


FIGURE 2.20 – Représentation graphique de la fonction Leaky ReLU et de sa dérivée. [36]

### 2.11.17 Fonction Hyperbolic tangent (TanH)

La fonction tangente hyperbolique ressemble à la fonction sigmoïde. La différence est que la fonction tanh produit un résultat compris entre -1 et 1. Elle est généralement utilisée comme fonction d'activation à l'intérieur du réseau au niveau des couches cachées par ce qu'elle admet des valeurs positives et négatives, ce qui augmente la capacité d'apprentissage du réseau. En revanche, on l'évite à la dernière couche si le résultat est le fruit d'une classification (valeur de 0 ou 1). [34]

L'expression littérale de la fonction sigmoïde s'écrit comme suit :

$$\text{Fonction : } \tanh(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$$

$$\text{Dérivée : } \frac{d \tanh(z)}{dz} = 1 - \tanh^2(z)$$

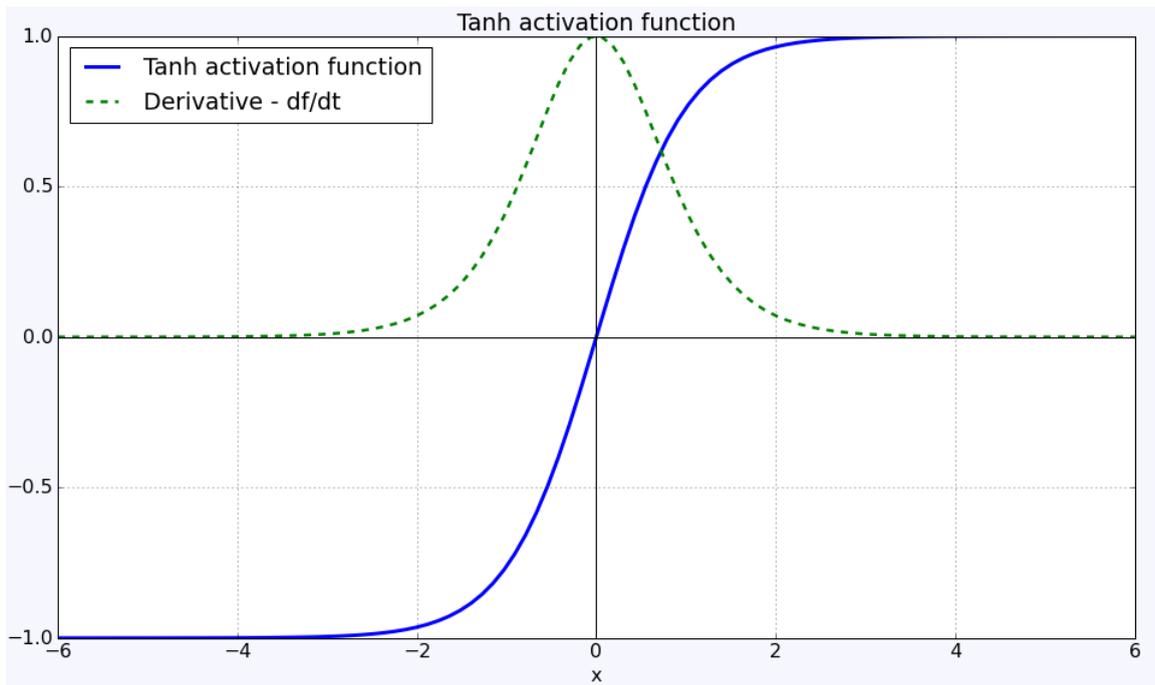


FIGURE 2.21 – Représentation graphique de la fonction Tanh et de sa dérivée. [36]

### 2.11.18 Fonction Unité exponentielle linéaire (ELU)

Elu est l'acronyme d'un terme anglicisme Exponential Linear Unit ou en français unité linéaire exponentielle. Autre dérivé de la ReLU. Celle-ci va approcher les valeurs moyennes proches de 0, ce qui va avoir comme impact d'améliorer les performances d'entraînements. Elle emploie une fonction exponentielle pour la partie négative au lieu d'une fonction linéaire. Elle paraît plus performante en expérimentation que les autres Relu. Pas de soucis de neurone mort (dying ReLU). [38]

L'expression littérale de la fonction sigmoïde s'écrit comme suit : [37]

$$\text{ELU}(z) = \begin{cases} z & \text{si } z \geq 0 \\ \varepsilon(e^z - 1) & \text{si } z < 0 \end{cases}$$

avec  $\varepsilon \in [0,1[$ , mais traditionnellement  $\varepsilon = 0.1$

$$\frac{d\text{ELU}(z)}{dz} = \begin{cases} 1 & \text{si } z \geq 0 \\ \text{ELU}(z) + \varepsilon & \text{si } z < 0 \end{cases}$$

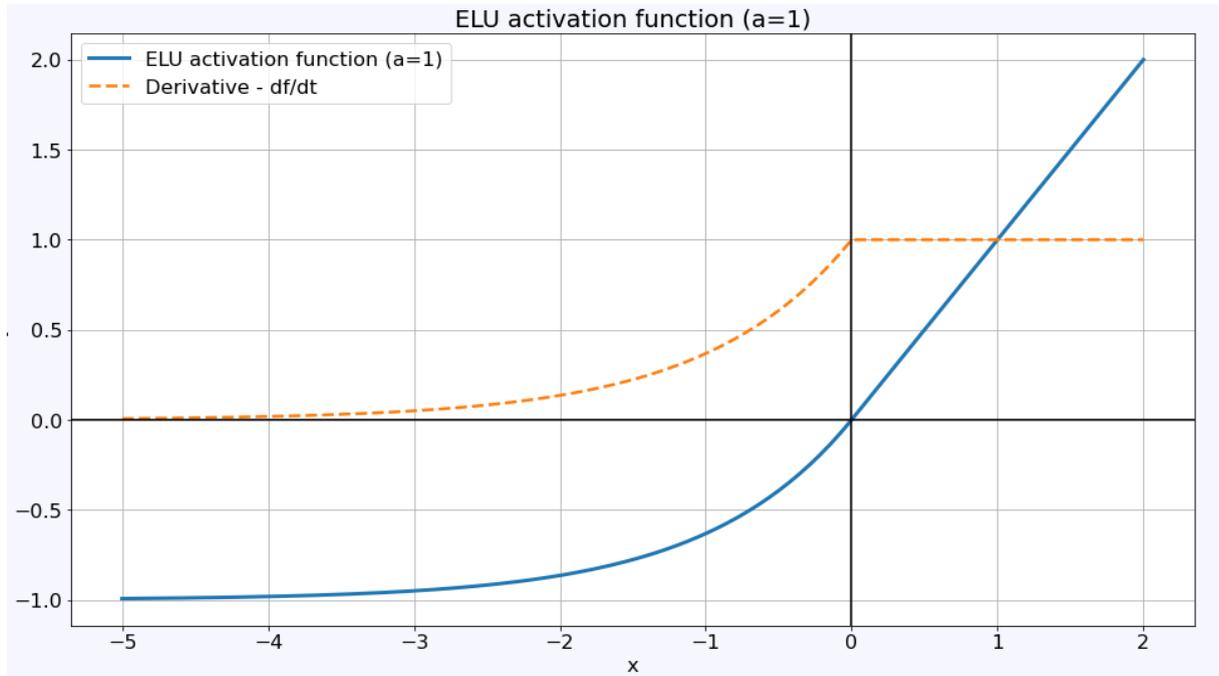


FIGURE 2.22 – Représentation graphique de la fonction ELU et de sa dérivée. [36]

### 2.11.19 Limite des techniques de l'intelligence artificielle dans le diagnostic médical

L'intelligence artificielle (IA) est devenue un outil inestimable dans le domaine médical, offrant des diagnostics rapides et précis dans de nombreux cas. Pourtant, elle n'est pas sans limites. Tandis que l'IA excelle dans l'analyse de grandes quantités de données, le diagnostic médical nécessite souvent une nuance et une compréhension que seuls les médecins, avec leur formation et leur expérience, peuvent offrir. La confiance est également un pilier de la médecine. Les patients se fient non seulement à l'expertise du médecin, mais également à son jugement, souvent façonné par des années de pratique clinique. Ainsi, bien que l'IA puisse être un complément précieux, elle ne peut remplacer le discernement et la confiance intrinsèque à la relation médecin-patient. Il est important de noter que les limites spécifiques de l'IA dans le diagnostic médical sont les suivantes :

- De nombreuses maladies sont peu documentées, avec peu de données accessibles. [48]
- Le manque de données labellisées, le traitement manuel étant très chronophage. [48]
- Dans les données accessibles, les classes sont très déséquilibrées (plus de patients sains que de malades ou l'inverse). [48]

- Les décisions prises par les algorithmes doivent être un maximum compréhensibles par les médecins (pas de “boîte noire”). [48]
- Lorsque entraînés sur des données biaisées, les algorithmes reproduisent par la suite ce biais. Or une grande partie des données médicales sont biaisées : mauvaise prise en charge des minorités, symptômes féminins non pris en compte. [48]

### 2.11.20 Défis de l’intelligence artificielle dans le diagnostic médical

L’intégration croissante de l’intelligence artificielle (IA) dans le domaine médical suscite un intérêt considérable, promettant des améliorations significatives dans la prestation des soins et la médecine en général. Cependant, avec ces opportunités émergent également des défis complexes qui nécessitent une approche réfléchie et éthique. Comme nous l’avons évoqué dans l’un des titres précédents, l’OMS souligne l’importance de placer l’éthique et les droits humains au cœur de la conception, du déploiement et de l’utilisation de l’IA médicale. Dans cette section, nous allons explorer de manière plus approfondie les défis spécifiques auxquels l’intelligence artificielle est confrontée dans le diagnostic médical. Nous examinerons en particulier les six principes clés publiés par l’OMS, visant à garantir que l’IA travaille au service de l’intérêt public et de la santé mondiale. Ces principes offrent un cadre essentiel pour guider l’adoption responsable de l’IA dans le secteur médical, en veillant à ce que tous les pays bénéficient d’une avancée médicale équitable et éthiquement alignée.

- **Protéger l’autonomie de l’être humain :** Dans le contexte des soins de santé, les individus doivent rester maîtres des systèmes de soins de santé et des décisions médicales, la vie privée et la confidentialité doivent être protégées et les patients doivent donner un consentement éclairé valide au moyen de cadres juridiques appropriés en matière de protection des données. [15]
- **Promouvoir le bien-être et la sécurité des personnes ainsi que l’intérêt public :** Les concepteurs de technologies d’IA doivent respecter les obligations réglementaires relatives à la sécurité, à la précision et à l’efficacité pour des utilisations ou des indications bien définies. Il faut pouvoir disposer de mesures de contrôle de la qualité dans la pratique et d’amélioration de la qualité dans l’utilisation de l’IA. [15]
- **Garantir la transparence, la clarté et l’intelligibilité :** La transparence exige que des informations suffisantes soient publiées ou documentées avant la conception ou le déploiement d’une technologie d’IA. Ces informations doivent être facilement accessibles et permettre une consultation et un débat publics constructifs sur la conception de la technologie et sur l’utilisation qui doit ou non en être faite. [15]
- **Encourager la responsabilité et l’obligation de rendre des comptes :** Même si les technologies d’IA permettent d’accomplir des tâches spécifiques, il incombe aux parties prenantes de veiller à ce qu’elles soient utilisées dans des conditions appropriées et par des personnes dûment formées. Des mécanismes efficaces doivent être mis en place pour permettre aux individus et aux groupes lésés par des décisions fondées sur des algorithmes de contester ces décisions et d’obtenir réparation. [15]
- **Garantir l’inclusion et l’équité :** L’inclusion suppose que l’IA appliquée à la santé soit conçue de manière à encourager l’utilisation et l’accès équitables les plus larges possibles, indépendamment de l’âge, du sexe, du genre, des revenus, de la race, de l’origine ethnique, de l’orientation sexuelle, des capacités ou d’autres caractéristiques protégées par les codes relatifs aux droits humains. [15]

- **Promouvoir une IA réactive et durable** : Les concepteurs, les développeurs et les utilisateurs devraient évaluer de manière continue et transparente les applications de l'IA en situation réelle afin de s'assurer que cette technologie répond de manière adéquate et appropriée aux attentes et aux besoins. Les systèmes d'IA devraient également être conçus de sorte à réduire au minimum leurs conséquences environnementales et à accroître leur efficacité énergétique. Les gouvernements et les entreprises devraient anticiper les bouleversements qui seront occasionnés au niveau du travail, notamment la formation des agents de santé qui devront se familiariser avec l'utilisation des systèmes d'IA, et les pertes d'emploi que le recours à des systèmes automatisés est susceptible d'engendrer. [15]

Ces principes guideront les travaux futurs de l'OMS en vue de garantir que le plein potentiel de l'IA en matière de soins de santé et de santé publique sera mis au service du bien de tous. [15]

Ces défis et limitations ne signifient pas que l'IA n'est pas utile ou prometteuse. Au contraire, ils mettent en évidence les domaines dans lesquels les chercheurs et les praticiens doivent concentrer leurs efforts pour rendre l'IA encore plus efficace et bénéfique pour la société.

## 2.12 Conclusion

En somme, ce chapitre a présenté un panorama complet de l'intégration croissante de l'intelligence artificielle dans le domaine médical, en prenant en compte les différentes dimensions du mélanome. Nous avons abordé en détail la définition, les causes, les symptômes, les stades de progression et les éventuelles complications de cette maladie, tout en mettant en évidence les options de traitement disponibles. En parallèle, nous avons exploré comment les techniques de l'intelligence artificielle sont appliquées dans le contexte du diagnostic médical, en nous penchant sur les défis et les limites spécifiques auxquels l'IA est confrontée dans ce domaine. En établissant le lien avec notre problématique spécifique, nous sommes désormais prêts à aborder les travaux récents les plus pertinents qui ont appliqué ces techniques pour la classification, en se focalisant beaucoup plus sur les réseaux de neurones convolutifs (CNN) dans le prochain chapitre.

# Chapitre 3

## Etat de l'art

### 3.1 Introduction

Le cancer de la peau est l'un des types de cancer les plus courants dans le monde. La détection précoce de cette maladie est essentielle pour améliorer les chances de guérison et sauver des vies. Au fil des ans, différentes approches ont été utilisées pour diagnostiquer le cancer de la peau, y compris l'examen visuel, la dermatoscopie et la biopsie. Cependant, ces méthodes peuvent être coûteuses, longues et potentiellement douloureuses pour les patients. Ces dernières années, l'apprentissage en profondeur a émergé comme une alternative prometteuse pour la détection et la classification automatiques du cancer de la peau. En effet, l'utilisation de réseaux de neurones profonds peut permettre d'améliorer la précision du diagnostic, tout en réduisant le coût et le temps de traitement. Dans cet état de l'art, nous allons passer en revue les différentes approches basées sur l'apprentissage en profondeur pour la détection et la classification du cancer de la peau, en mettant en évidence les avantages et les limites de ces techniques. Nous discuterons également des perspectives futures pour l'amélioration de ces approches et pour leur intégration dans la pratique clinique.

### 3.2 Travaux connexes

L'utilisation de l'apprentissage profond dans la détection de mélanome est devenue une méthode de plus en plus populaire ces dernières années. Dans ce domaine, plusieurs études ont été réalisées pour déterminer l'efficacité de l'apprentissage profond dans la détection de mélanome. Les travaux de recherche suivants ont notamment été réalisés :

1. **Catarina et al**[70] : L'article publié dans Nature Medicine présente un modèle d'apprentissage par renforcement conçu spécifiquement pour le diagnostic du cancer de la peau. Ce modèle vise à adapter les prédictions de l'intelligence artificielle (IA) en fonction des préférences humaines. Les chercheurs ont utilisé des récompenses et des pénalités non uniformes, basées sur des tables générées par des experts, pour équilibrer les avantages et les inconvénients des différentes erreurs de diagnostic. Les résultats ont montré que, par rapport à un modèle d'apprentissage supervisé traditionnel, le modèle d'apprentissage par renforcement a amélioré la sensibilité du diagnostic pour des cancers spécifiques comme le mélanome et le carcinome basocellulaire. De plus, ce modèle a maintenu une précision moyenne élevée, démontrant son efficacité. L'étude souligne l'importance de prendre en compte les préférences humaines lors de la conception de systèmes d'IA, en particulier dans des domaines aussi critiques que la médecine.

2. **Ghadah et al** [71] : Dans le cadre de cette recherche, les auteurs ont utilisé des modèles de deep learning, notamment Inception-V3 et InceptionResnet-V2, pour détecter le mélanome. Ces modèles ont été formés en utilisant le jeu de données HAM10000, qui contient des images de sept types différents de cancers de la peau. Pour pallier le déséquilibre des données, les chercheurs ont eu recours à des techniques d'augmentation des données. En fin de compte, les modèles proposés ont montré une efficacité impressionnante, surpassant les études précédentes avec des scores de 0,89 pour Inception-V3 et 0,91 pour InceptionResnet-V2.
3. **Anand et al**[72] : Cette recherche présente une base de données annotée de réseaux irréguliers et développe un pipeline de classification qui fusionne les résultats d'images basés sur l'apprentissage profond avec des caractéristiques artisanales conventionnelles issues des réseaux de pigments irréguliers. En utilisant le modèle de segmentation U-Net++, combiné à d'autres caractéristiques classiques de couleur, de texture et de forme, une augmentation de la précision du diagnostic du mélanome a été obtenue. L'approche proposée vise à combiner les forces de l'apprentissage profond et des techniques de traitement d'images conventionnelles pour améliorer la précision du diagnostic du mélanome. En conclusion, l'approche proposée facilite l'exploitation des forces de l'apprentissage profond et des techniques de traitement d'images conventionnelles pour améliorer la précision du diagnostic du mélanome.
4. **Ghadah et al**[67] : cette étude propose une méthode de détection de mélanome en utilisant une approche d'apprentissage profond basée sur des classifications. Les auteurs ont utilisé un réseau de neurones convolutionnel pour extraire les caractéristiques des images de mélanome et un classificateur pour la classification et ont obtenu un taux de précision de 86% et 85% en utilisant une version modifiée de Resnet-50.
5. **Arthur et al** [73] : Cette étude présente un nouveau cadre par les auteurs pour le diagnostic automatisé du mélanome. Outre l'amélioration des performances des systèmes existants, leur approche tente également d'apporter plus de transparence dans le processus décisionnel. Le cadre proposé comprend un CNN multi-classes et six CNN binaires assimilés à des joueurs. Ces joueurs stratègisent d'abord pour classer les lésions pigmentées (mélanome, nævus, kératose bénigne) en fonction du niveau de confiance (confiant, moyen, incertain). Ensuite, un sous-ensemble de joueurs, toujours selon leur approche, affine le diagnostic pour les lésions difficiles. L'approche a été évaluée sur le jeu de données public ISIC constitué de 8917 lésions. Elle a atteint une AUC de 0,93 pour le mélanome, 0,96 pour le nævus et 0,97 pour la kératose bénigne. De plus, leur méthode a surpassé les méthodes existantes, améliorant la précision équilibrée de la meilleure méthode comparée de 77 % à 86 %. Ces résultats suggèrent que leur cadre offre une stratégie décisionnelle efficace et explicable, pouvant aider les dermatologues dans leur pratique clinique pour les lésions pigmentées atypiques et difficiles à diagnostiquer.
6. **Pewton et Yap** [74] : Les ensembles de données d'images de lésions cutanées ont gagné en popularité récemment. Cet article se penche sur le phénomène des coins sombres (DCA) dans ces ensembles de données, cherchant à comprendre comment et pourquoi ils se produisent. L'objectif est de développer des méthodes efficaces pour traiter ces artefacts. L'article présente une méthode dynamique pour éliminer l'artefact des images, offrant une compréhension approfondie des ensembles de données de lésions cutanées, des artefacts et du phénomène DCA. Une méthode efficace de masquage et de suppression de DCA est également introduite. Les résultats montrent que les images avec de grands

DCA sont souvent incorrectement prédites comme appartenant à la classification "mel" (mélanome).

7. **Marriam et al** [75] : Dans cet article, les auteurs présentent une méthode entièrement automatisée pour segmenter le mélanome cutané à ses premiers stades. Cette méthode utilise une approche basée sur l'apprentissage profond appelée "faster region-based convolutional neural networks (RCNN)" en combinaison avec le clustering "fuzzy k-means (FKM)". La méthode commence par prétraiter les images du dataset pour éliminer le bruit et les problèmes d'éclairage, puis améliore l'information visuelle. Ensuite, le faster-RCNN est utilisé pour obtenir un vecteur de caractéristiques de longueur fixe. Après cela, le FKM est utilisé pour segmenter la portion de peau affectée par le mélanome. La performance de cette méthode a été évaluée sur trois datasets standards : ISBI-2016, ISIC-2017 et PH2. Les résultats montrent que la méthode proposée surpasse les approches actuelles. Elle atteint une précision moyenne de 95,40% sur ISIC-2016, 93,1% sur ISIC-2017 et 95,6% sur PH2, démontrant ainsi sa robustesse pour la reconnaissance et la segmentation des lésions cutanées.
8. **G. Nadjette et al**[78] : cette étude examine les performances des réseaux ResNet-50 et Inception-V3 dans la classification de cancer de la peau. Les auteurs ont utilisé des données provenant de la base de données ISIC (International Skin Imaging Collaboration) pour entraîner et tester les réseaux. Les auteurs ont obtenu un taux de précision de 65% pour ResNet-50 et de 99% pour Inception-v3.
9. **Shubhendu et al**[68] : cette étude propose une méthode de diagnostic de mélanome en utilisant une approche d'apprentissage profond et de logique floue. Les auteurs ont utilisé un réseau de neurones convolutionnel pour extraire les caractéristiques des images et ont utilisé la logique floue pour la classification et ont obtenu un taux de précision de 97.11%.
10. **Zunair et Ben Hamza**[77] : L'article traite de la détection du mélanome à l'aide de techniques d'apprentissage avancées. Les ensembles de données sur les lésions cutanées contiennent principalement des échantillons normaux avec seulement un faible pourcentage d'échantillons anormaux, ce qui crée un problème de déséquilibre des classes. De plus, les images des lésions cutanées se ressemblent beaucoup en raison de la faible variabilité entre les classes. Les auteurs proposent une approche en deux étapes pour la classification automatique des images de lésions cutanées en utilisant une formation adverse et un apprentissage par transfert pour la détection du mélanome.

Dans la première étape, ils exploitent la variation entre les classes de la distribution des données pour la synthèse d'images conditionnelle. Ils apprennent le mappage entre les classes et synthétisent des échantillons de classes sous-représentées à partir de ceux sur-représentés en utilisant une traduction d'image non appariée. Dans la deuxième étape, ils forment un réseau neuronal convolutionnel profond pour la classification des lésions cutanées en utilisant l'ensemble d'entraînement original combiné aux échantillons de classe sous-représentée nouvellement synthétisés. La formation de ce classificateur est effectuée en minimisant la fonction de perte focale, aidant le modèle à apprendre des exemples difficiles tout en sous-pondérant les exemples faciles. Les expériences menées sur un benchmark d'images dermatologiques montrent que leur approche est supérieure à plusieurs méthodes de base, avec des améliorations significatives des performances. De manière intéressante, leur méthode conduit à une évaluation des lésions basée sur le

contexte qui peut atteindre le niveau d'un dermatologue expert.

11. **Devansh et al** [69] : cette étude propose une méthode de purification et d'augmentation de données pour améliorer les performances de détection de mélanome avec l'apprentissage profond. Les auteurs ont utilisé un réseau de neurones convolutionnel pour la classification des images de mélanome et ont testé leur méthode sur la base de données ISIC et ont obtenu un taux de précision de 81.6%.
12. **Nudrat et al**[76] : Dans cet article, une méthode d'apprentissage profond est proposée pour la segmentation automatisée de la région du mélanome à l'aide d'images dermoscopiques. La méthode utilise un réseau neuronal convolutionnel basé sur des régions profondes (RCNN) pour détecter précisément les régions affectées sous forme de boîtes englobantes. Ces régions sont ensuite localisées à l'aide du clustering Fuzzy C-mean (FCM). La méthode a été appliquée sur un ensemble de données de référence ISIC-2016, et les résultats ont démontré une performance de segmentation supérieure par rapport aux méthodes existantes.
13. **Gouabouet al**[3] : cette étude propose une méthode d'apprentissage profond pour la classification des images de mélanome. Les auteurs ont utilisé un réseau de neurones convolutionnel (CNN) pour extraire les caractéristiques des images et un classificateur pour identifier les images de mélanome et ont trouvé que l'approche par apprentissage profond, malgré le nombre limité de données, a donné des résultats comparables à l'approche classique, avec une sensibilité de 78%, et une spécificité de 83%.

En résumé, l'utilisation de l'apprentissage profond pour la détection de mélanome est une méthode prometteuse, mais elle nécessite encore de nombreuses améliorations et d'investigations. Des recherches futures pourraient explorer des techniques telles que la segmentation d'image et la fusion de données multimodales pour améliorer la précision de la détection de mélanome avec l'apprentissage profond. De plus, l'évaluation de l'impact de l'interprétabilité des modèles et de la fiabilité des prédictions devra être étudiée. Enfin, il est important de travailler avec des experts médicaux pour s'assurer que les résultats obtenus sont pertinents et utiles dans la pratique clinique.

### 3.3 Exploration approfondie et comparaison des diverses approches

1. Critères de comparaison Dans les tableaux ci-dessous nous effectuerons une étude comparative des approches proposées ci-dessus selon les 8 facteurs suivants :
  - **Approche** : Désigne l'approche de chaque papier.
  - **Dataset** : Indique les sources de données utilisée pour l'implémentation de l'approche pour la prédiction du mélanome.
  - **Techniques utilisées** : Les techniques utilisées pour prédire le mélanome.
  - **Avantages** : Avantages de l'approche abordée.
  - **Inconvénients** : Inconvénients de l'approche abordée.
  - **Méthodologie** : Étude systématique, par observation de la pratique scientifique, des principes qui la fondent et des méthodes de recherche utilisées.
  - **Résultats** : Les résultats de l'approche.

- **Nombre d'images** : Correspond au volume total d'images utilisées dans le papier ou la recherche, ce qui permet d'indiquer la taille de l'échantillon sur lequel l'approche a été testée.

### 2. Étude Comparative des Articles :

La classification du mélanome a connu des avancées significatives avec l'adoption des techniques d'intelligence artificielle. Ces techniques, enrichies par des algorithmes de plus en plus sophistiqués et des ensembles de données conséquents, ont modifié la manière dont les professionnels abordent la détection et la classification de cette maladie cutanée. Dans cette section, nous analysons 13 articles clés qui incarnent la pointe de la recherche actuelle en matière de classification du mélanome par l'IA. Ce panorama aspire à orienter et informer chercheurs, cliniciens et autres acteurs clés sur les possibilités et les défis actuels associés à l'IA dans le contexte de la classification du mélanome.

Approche	Dataset	Techniques utilisées	Avantages	Inconvénients	Méthodologie	résultats	nombre d'images
<b>A reinforcement learning model for AI-based decision support in skin cancer (27 juillet 2023)</b>	- HAM10000 dataset : Ce dataset a été utilisé pour entraîner le modèle SL (Supervised Learning) et le modèle RL (Reinforcement Learning). -ISIC 2018 : Utilisé comme ensemble de test indépendant pour l'étude des lecteurs et pour la validation externe des modèles SL et RL.	deux techniques utilisées : - l'apprentissage supervisé (SL) - l'apprentissage par renforcement (RL).	- En tenant compte des préférences humaines, le système d'IA peut être optimisé pour prendre des décisions conformes aux préférences des professionnels de la santé, ce qui conduit à une meilleure précision diagnostique et à des décisions de prise en charge améliorées. - L'utilisation de l'apprentissage par renforcement permet la création d'approches personnalisées dans des scénarios cliniques complexes, optimisant les points de fonctionnement sur les courbes de décision et améliorant les décisions de prise en charge.	-Le modèle d'apprentissage par renforcement utilisé dans cette approche nécessite un réapprentissage, ce qui peut être chronophage et nécessite plus de ressources par rapport à des approches plus simples comme le seuillage. -Des recherches supplémentaires sont nécessaires pour comprendre pleinement le potentiel de l'apprentissage par renforcement et pour évaluer la satisfaction des patients et des prestataires en ce qui concerne les outils d'aide à la décision basés sur l'IA.	-Les auteurs ont utilisé des récompenses et des pénalités non uniformes basées sur des tableaux générés par des experts, équilibrant les avantages et les inconvénients des différentes erreurs de diagnostic, qui ont été appliquées en utilisant l'apprentissage par renforcement	Sensibilité pour le mélanome : Elle est passée de 61,4% avec l'apprentissage supervisé à 79,5% avec l'apprentissage par renforcement. L'intervalle de confiance à 95% (IC) était de 73,5–85,6%. Sensibilité pour le Carcinome Basocellulaire : Elle est passée de 79,4% à 87,1%. L'IC à 95% était de 80,3–93,9%. -L'apprentissage par renforcement a augmenté le taux de diagnostics corrects faits par les dermatologues de 12,0%. L'IC à 95% pour cette amélioration était de 8,8–15,1%. -Le taux de décisions de gestion optimales a amélioré de 57,4% à 65,3%. L'IC à 95% était de 61,7–68,9%.	-HAM 10000 dataset : 10015 images -ISIC 2018 : Cet ensemble comprend 1,511 images dermatoscopiques collectées rétrospectivement de différents sites pour assurer la diversité des types de peau.

<p><b>Diagnosing Melanomas in Dermoscopy Images Using Deep Learning (22 mai 2023)</b></p>	<p>HAM10000</p>	<p>Apprentissage profond basé sur des réseaux de neurones convolutifs</p>	<ul style="list-style-type: none"> <li>- Permet de diagnostiquer rapidement et précisément le mélanome à partir d'images dermatoscopiques.</li> <li>- Améliore les performances des modèles existants en termes de précision et d'équilibre. -Utilise l'augmentation des données pour corriger le déséquilibre du dataset.</li> </ul>	<ul style="list-style-type: none"> <li>- Nécessite une grande puissance de calcul et de stockage.</li> <li>- Peut être sensible au bruit et aux artefacts dans les images.</li> <li>- Manque d'explicabilité et d'interprétabilité des décisions.</li> </ul>	<ul style="list-style-type: none"> <li>- Utilisation d'un réseau Mask R-CNN pour recadrer automatiquement la région d'intérêt dans l'image.</li> <li>- Utilisation d'un réseau Inception-V3 ou Inception-Resnet-V2 pré-entraîné sur ImageNet pour la classification binaire des lésions.</li> <li>-Ajustement fin des couches d'extraction de caractéristiques après l'entraînement des couches supérieures ajoutées.</li> </ul>	<p>Précision de 0,89 pour Inception-V3 et 0,91 pour Inception-Resnet-V2.          Sensibilité et spécificité supérieures à 0,8 pour les deux modèles.</p>	<p>10 015 images de sept types différents de cancer de la peau.</p>
---	-----------------	---	---	--	--	---	---

<p><b>Improving Automatic Melanoma Diagnosis Using Deep Learning-Based Segmentation of Irregular Networks (16 février 2023)</b></p>	<p>ISIC 2019 dermoscopic dataset</p>	<p>-Segmentation basée sur le transfert d'apprentissage avec des architectures ResNet, DenseNet et MobileNet. -Classification basée sur l'apprentissage profond supervisé avec des architectures ResNet, DenseNet et MobileNet. -Fusion basée sur la concaténation des caractéristiques extraites par les modèles de segmentation et de classification.</p>	<p>- Présente une méthode de classification des mélanomes basée sur la détection des réseaux pigmentaires irréguliers à l'aide de l'apprentissage profond. -Combine les résultats de la segmentation avec une méthode d'apprentissage profond supervisé sur l'image entière pour améliorer la précision du diagnostic.</p>	<p>- La base de données annotée est limitée en taille et en diversité. -La méthode de segmentation n'est pas parfaite et peut produire des faux positifs ou des faux négatifs. -La méthode de fusion n'est pas optimale et peut être améliorée avec d'autres techniques.</p>	<p>- Création d'une base de données annotée de réseaux pigmentaires irréguliers à partir des images du dataset ISIC 2019. -Entraînement de plusieurs modèles de segmentation basés sur le transfert d'apprentissage pour détecter les réseaux pigmentaires irréguliers. -Entraînement d'un classificateur linéaire sur les caractéristiques fusionnées pour prédire la présence ou l'absence de mélanome.</p>	<p>- Le modèle de segmentation le plus performant est le ResNet-50 avec un score Dice de 0,71 et un score IoU de 0,56. -Le modèle de classification le plus performant est le ResNet-50 avec un score AUC de 0,94 et un score F1 de 0,84. -Le modèle de fusion obtient un score AUC de 0,95 et un score F1 de 0,86, ce qui est légèrement supérieur au modèle de classification seul.</p>	<p>487 images</p>
---	--------------------------------------	---	--	--	---	---	-------------------

<p><b>Melanoma Detection Using Deep Learning-Based Classifications (8 décembre 2022)</b></p>	<p>Ensemble de données d'images de lésions connu sous le nom de HAM10000</p>	<p>-réseau de neurones convolutionnel (CNN) - une version modifiée de Resnet-50</p>	<p>-une technique innovante de pré-traitement des images (ESRGAN) qui améliore la qualité des images de lésions cutanées. - L'utilisation de la segmentation pour extraire les régions d'intérêt et la data augmentation pour corriger les disparités dans les données améliorent l'efficacité de la méthode. - améliorer la précision du diagnostic des cancers de la peau. - rapide et précise, avec une précision de classification des lésions cutanées comparable à celle des dermatologues professionnels</p>	<p>-limiter la généralisation de la méthode à d'autres populations - Les résultats obtenus ne sont pas encore suffisamment robustes pour être utilisés comme méthode de diagnostic autonome sans l'aide d'un professionnel de la santé. - limiter son applicabilité dans des contextes avec des ressources limitées, puisque ça nécessite des équipements informatiques sophistiqués pour l'analyse des images,</p>	<p>diagnostiquer promptement et avec précision sept différents types de cancer en analysant des lésions cutanées. -techniques d'amélioration d'image pour éclaircir l'image de la lésion et éliminer le bruit.</p>	<p>Best accuracy using CNN learning model : 86% the modified version of Resnet-50 : 85%</p>	<p>10000 images</p>
--	--	---	---	---	--	---	---------------------

<p><b>Computer Aided Diagnosis of Melanoma Using Deep Neural Networks and Game Theory : Application on Dermoscopic Images of Skin Lesions (10 novembre 2022)</b></p>	<p>ISIC 2018</p>	<p>CNN(Convolutional Neural Network) Game Theory</p>	<p>-le processus de décision est plus intuitif et explicable ce qui encourage à l'utiliser dans des cas clinique réels -une stratégie de prise de décision efficace et explicable. -aider les dermatologues dans leur pratique clinique pour les patients atteints de lésions pigmentées atypiques et difficiles à diagnostiquer. -servir d'outil didactique pour les dermatologues moins expérimentés.</p>	<p>-les performances prédictives de framework doivent être améliorées, avec un accent particulier sur la réduction des taux de faux négatifs et l'atténuation du problème de déséquilibre des classes. -une validation clinique n'a pas encore été faite pour l'utiliser dans des contextes cliniques réels comme outil de formation pour les dermatologues débutants.</p>	<p>L'approche proposée combine sept modèles CNN à travers la théorie des jeux et la combine avec la visualisation de la carte thermique. et introduit une nouvelle méthode pour évaluer le niveau de confiance d'une prédiction générée par un système automatisé et a été intégrée dans un framework.</p>	<p>AUROC of 96% minimum margin of 9% in terms of BACC.</p>	<p>8917 lesions : Melanoma (1 113), Nevi (6 705) Benign Keratosis (1 099) 70% training images, 10% validation images, 20% test images</p>
--	------------------	--	---	--	--	--	---

<p><b>Dark Corner on Skin Lesion Image Dataset : Does it matter? (23 aout 2022)</b></p>	<p>-ISIC (International Skin Imaging Collaboration). -dataset Dermofit NOM</p>	<p>- Réseau de neurones convolutif (CNN). - Remplissage par patches Technique utilisé</p>	<p>- Permet de mieux comprendre le phénomène des DCA et ses effets sur la classification des lésions cutanées. -Il présente une méthode dynamique pour éliminer l'artefact des images, ce qui pourrait améliorer la qualité des images. -Améliore la qualité des images et réduit l'impact des DCA sur la classification binaire des lésions cutanées. AVANTAGES</p>	<p>- La méthode nécessite plusieurs étapes de prétraitement, y compris l'utilisation de Grad-CAM, ce qui pourrait la rendre complexe à mettre en œuvre. -La méthode de suppression des DCA n'est pas évaluée sur d'autres types de classification ou d'autres ensembles de données.</p>	<p>- Création d'un ensemble de données équilibré avec des labels DCA ou non à partir du dataset ISIC -Développement d'un CNN pour détecter les DCA dans les images -Développement d'une technique de remplissage par patches pour supprimer les DCA dans les images -Évaluation de la qualité des images après suppression des DCA sur un ensemble de données externe (Dermofit) avec des métriques telles que le SSIM et le PSNR</p>	<p>- La méthode de suppression des DCA obtient un meilleur score SSIM (Structural Similarity Index Measure) que la méthode de base sur un ensemble de données externe (Dermofit)</p>	<p>-9,810 images ( 7,848 images pour l'entraînement et 1,962 images pour la validation ) dans le dataset ISIC. -1,300 images dans le dataset Dermofit IMAGES</p>
---	--	---	--	---	---	--	--

					-Évaluation de l'effet de la suppression des DCA sur la classification binaire des lésions cutanées avec EfficientNet-B0		
<b>Skin cancer detection from dermoscopic images using deep learning and fuzzy k-means clustering (aout 2021)</b>	la méthode présentée a été évaluée sur trois ensembles de données standard, à savoir ISBI-2016, ISIC-2017 et PH2	La technique utilisée dans cette étude est une approche basée sur l'apprentissage en profondeur, à savoir les réseaux de neurones convolutionnels régionaux plus rapides (RCNN) avec un regroupement de moyennes floues (FKM)	-L'article explore l'utilisation de l'apprentissage profond et du regroupement flou k-moyennes pour la détection du cancer de la peau, qui sont des techniques avancées dans le domaine de l'analyse d'images médicales. -Robustesse à la reconnaissance et à la segmentation des lésions cutanées. -Détection exacte et précise des lésions cutanées grâce à la puissance de localisation précise du RCNN plus rapide.	-L'article ne fournit pas une analyse complète des limitations ou des sources potentielles d'erreur dans la méthode proposée. -L'article ne discute pas des exigences ou limitations computationnelles de la méthode proposée, ce qui pourrait être des considérations importantes pour sa mise en œuvre pratique.	-Un prétraitement est effectué pour éliminer les artefacts des images d'entrée qui peuvent fausser la puissance de détection de faster-RCNN. - Ces images traitées sont ensuite soumises à la technique d'apprentissage profond faster-RCNN pour identifier la partie mélanome.	ISIC-2016 dataset : Accuracy : 0.954 Sensitivity : 0.90 Specificity : 0.971 ISIC-2017 dataset : Accuracy : 0.952 Sensitivity : 0.861 Specificity : 0.982 PH2 dataset : Accuracy : 0.961 Sensitivity : 0.970 Specificity : 0.972	ISIC-2016 : un total de 1 280 images, 900 training 380 testing -PH2 total 200 échantillons avec 40 images de mélanomes - ISIC-2017 : 2000 training 150 validation 600 testing.

					- l'algorithme de regroupement FKM est utilisé sur les résultats détectés pour segmenter la partie affectée des images, qui peut être utilisée ultérieurement pour la reconnaissance de la maladie du mélanome		
<b>Étude et expérimentation des réseaux Resnet-5-0 et Inception-V3 dans la classification de cancer de la peau (2021)</b>	base de données ISIC-2020	l'apprentissage profond et la reconnaissance de formes -le réseau pré-entraîné ResNet-50 -le réseau pré-entraîné Inception-v3	-améliorer le diagnostic du cancer de la peau et du mélanome, -rendre le processus de diagnostic plus efficace et plus précis. -le modèle basé sur Inception-v3 a obtenu un taux de reconnaissance élevé de 99%, ce qui est encourageant pour une utilisation potentielle dans la pratique clinique.	-Le taux de reconnaissance de 65% pour le modèle basé sur ResNet-50 pourrait être considéré comme relativement faible pour une utilisation en pratique clinique, -il est important de tester ces modèles sur d'autres bases d'images dermoscopiques pour évaluer leur généralisation.	étudié et expérimenté deux modèles de classification d'images dermoscopiques -distinguer 9 classes de cancer de la peau -distinguer deux classes de cancer de la peau, le mélanome malin/bénin	-Resnet-50 avec un taux de reconnaissance de 65%. - Inception-v30 avec taux de reconnaissance de 99%	5000 images

<p><b>Melanoma Diagnosis Using Deep Learning and Fuzzy Logic (9 Août 2020)</b></p>	<p>trois ensembles de données distincts :- PH2 -ISBI2017 -ISIC 2019</p>	<p>- Réseaux de neurones convolutionnels profonds (DCNNs) - You Only Look Once (YOLO) - Segmentation à partir par la théorie des graphes et le concept d'arbre couvrant minimal - Nombres flous de type L</p>	<p>- Utilise un algorithme basé sur les réseaux de neurones convolutionnels profonds (DCNNs) pour détecter le mélanome à partir d'images dermatoscopiques et numériques. - Offre une sortie plus rapide et plus précise que les CNNs conventionnels. - Utilise des concepts de segmentation, de logique floue et de théorie des graphes pour améliorer le processus d'extraction des caractéristiques et la précision du diagnostic. - l'utilisation des ensembles de données différents renforce la validité de la méthode.</p>	<p>méthodes existantes. - la généralisation des résultats peut être affecté - N'a pas évalué l'impact de la taille et de la qualité des images sur les résultats. - N'a pas fourni de détails sur la configuration matérielle et logicielle utilisée pour l'expérimentation.</p>	<p>de gris, re-dimensionnement, normalisation et augmentation des données. - Segmentation des images : utilisation d'un algorithme basé sur la théorie des graphes et le concept d'arbre couvrant minimal pour extraire la région d'intérêt. - Extraction des caractéristiques : utilisation d'un algorithme basé sur les nombres flous de type L pour approximer les caractéristiques géométriques de la région d'intérêt. - Classification des images utilisation DCNNs</p>	<p>2019. - A obtenu un score Jac de 86,99% sur l'ensemble de données ISBI 2017. - A obtenu un score Jac de 88,64% sur l'ensemble de données PH2.</p>	<p>images from ISBI 2017 -17300 images from ISIC2019</p>
--	---	---	--	--	---	--	--

<p><b>Melanoma Detection using Adversarial Training and Deep Transfer Learning(14 avril 2020)</b></p>	<p>ISIC-2016 dataset</p>	<p>adversarial training, transfer learning</p>	<p>- la découverte visuelle de fortes activations pour les régions entourant la lésion cutanée, conduisant à une évaluation de la lésion basée sur le contexte qui peut atteindre le niveau d'un dermatologue expert. -MelaNet donne le plus faible nombre de faux négatifs, -Cette méthode permet de surmonter le problème de déséquilibre de classes dans les données de lésions cutanées en générant des échantillons synthétiques de la classe minoritaire pour améliorer la précision de la détection de mélanome.</p>	<p>-La méthode nécessite beaucoup de données d'entraînement pour être efficace, car elle repose sur la capacité de générer des échantillons synthétiques représentatifs de la classe minoritaire. Si les données sont très limitées, la méthode pourrait ne pas être aussi performante. -La méthode nécessite également des ressources informatiques importantes, car elle utilise l'entraînement adversarial, qui est un processus intensif en termes de temps et de calcul.</p>	<p>Deux étapes : 1- des images dermoscopiques synthétiques sont générées pour la classe minoritaire (c'est-à-dire les images malignes) en utilisant une traduction d'image à image non appariée dans le but d'équilibrer l'ensemble d'entraînement. Ces images supplémentaires sont ensuite utilisées pour renforcer l'entraînement. 2-</p>	<p>La méthode MelaNet a montré une amélioration de la sensibilité de 13,10% et de l'AUC de 0,78% par rapport aux méthodes de base, avec seulement 1627 images de dermoscopie. -AUC : 81,18% - Sensibilité : 91,76%</p>	<p>900 training : 727 benign 173 maligne 379 test</p>
---	--------------------------	--	---	---	---	--	---

			<p>- La méthode utilise un réseau de neurones convolutionnels profond pour la classification de lésions cutanées, qui a montré des performances significativement meilleures que les méthodes de base dans les expériences menées.</p>				
--	--	--	--	--	--	--	--

<p><b>Towards Automated Melanoma Detection with Deep Learning :Data Purification and Augmentation (17 juin 2019)</b></p>	<p>_ISIC-2017 -PH2 - the Edinburgh data se</p>	<p>-l'apprentissage profond - réseaux de génération adverse (GAN)</p>	<p>-Améliorer la détection précoce du mélanome, ce qui est crucial pour la survie des patients. -compenser les limitations des bases de données disponibles. -En utilisant ces outils, les chercheurs ont réussi à améliorer les performances de leur système de détection de mélanome.</p>	<p>-il est possible que ces résultats ne soient pas généralisables à d'autres ensembles de données. -des limites en termes de représentativité des données réelles. -prendre en compte les limites et les biais potentiels du modèle, ainsi que de procéder à des validations cliniques avant de mettre en pratique le système de détection de mélanome automatisé.</p>	<p>- purification et l'augmentation de données -Éliminer les occlusions des images et de générer des images synthétiques pour les classes de lésions rares - Créer des patients virtuels avec des types de lésions prédéfinis</p>	<p>81.6% accuracy on the task of classifying images into three categories</p>	<p>-3198 from ISIC-2017 -120 from PH2 -664 from the Edinburgh data set</p>
--	--	---	---	---	---	---	--

<p><b>Melanoma lesion detection and segmentation using deep region based convolutional neural network and fuzzy C-means clustering (Avril 2019)</b></p>	<p>dataset ISIC-2016 byInternational Symposium on biomedical images (ISBI)</p>	<p>réseau de neurones convolutifs régionaux profonds (RCNN) et le regroupement flou de C-mean(FCM).</p>	<p>La méthode proposée est capable de segmenter efficacement les régions de mélanome dans les images dermoscopiques, ce qui pourrait aider les dermatologues à détecter les lésions de mélanome plus tôt et à améliorer les résultats des traitements. *La méthode utilise un réseau de neurones convolutifs de régions profondes (RCNN) pour détecter les régions affectées de manière précise et un algorithme de clustering FCM pour localiser les régions de mélanome, ce qui est une méthode avancée et prometteuse pour la segmentation d'images médicales.</p>	<p>-*Les performances de la méthode peuvent être limitées si les images dermoscopiques ne sont pas de qualité suffisante ou si les données d'entraînement sont insuffisantes. *La méthode proposée nécessite un traitement en plusieurs étapes, ce qui peut rendre le processus de segmentation plus complexe et plus lent que certaines méthodes plus simples. *Bien que la méthode soit capable de détecter plusieurs maladies de la peau chez le même patient, elle n'est pas en mesure de fournir des informations sur la nature spécifique de chaque lésion, ce qui pourrait</p>	<p>Cette méthode se compose de trois étapes : le raffinement de la peau, la localisation de la région de mélanome et enfin la segmentation de mélanome.</p>	<p>Ac0.94 SP0.94 Di :0.93 Jc :0.942 time :0.08</p>	<p>900 training 376 testing</p>
---	--	---	---	---	---	--	-------------------------------------

			<p>*La méthode est testée sur un ensemble de données standard (ISBI-2016) et a montré des performances supérieures à celles des méthodes existantes pour la segmentation de mélanome.</p> <p>*La méthode peut détecter plusieurs maladies de la peau chez le même patient ainsi que diverses maladies chez différents patients avec un mécanisme d'apprentissage efficace et en fonction des données d'apprentissage suffisantes.</p> <p>-résoudre des problèmes complexes de segmentation d'images médicales</p>	<p>limiter son utilité pour certaines applications cliniques.</p>			
--	--	--	---	---	--	--	--

<p><b>Apprentissage profond pour l'aide au diagnostic du mélanome à partir d'exemple (2019)</b></p>	<p>base de données ISIC (International Skin Imaging Collaboration)</p>	<p>l'apprentissage profond -les réseaux de neurones convolutifs (CNN) -les réseaux de neurones résiduels (ResNet) -les architectures d'encodage-décodage U-Net</p>	<p>-la capacité à apprendre des caractéristiques hautement discriminantes à partir de grandes quantités de données -la possibilité de traiter des images en temps réel -Les résultats obtenus sont satisfaisants et comparables à l'approche classique de l'apprentissage automatique - l'exploration des techniques pour pallier le déséquilibre des bases de données et l'utilisation de bases de données plus larges.</p>	<p>-nécessité d'une grande quantité de données et la difficulté de les interpréter. -Les modèles développés ont été évalués sur des images dermatoscopiques, mais leur performance n'a pas été évaluée sur des images cliniques -les propriétés des fonctions de coût utilisées par les modèles</p>	<p>classification de lésions mélanocytaires</p>	<p>Approche classique : sensibilité=89% spécificité=77% approche par apprentissage profond sensibilité=78% spécificité=83%</p>	<p>1356 images</p>
---	--	--	--	---	---	--	--------------------

TABLE 3.1 – Table comparative

Dans cette étude, nous avons effectué un état de l'art des travaux les plus récents dans le domaine de la détection et de la classification des mélanomes à partir d'images dermatoscopiques. Nous avons examiné cinq chapitres, chacun présentant des approches différentes pour résoudre ce problème, en utilisant des techniques de deep learning, telles que les réseaux de neurones convolutifs (CNN), pour améliorer la précision et la performance.

Nous avons étudié comment les travaux examinés ont tenté d'analyser les données et d'obtenir de meilleurs résultats en termes de précision, de rappel et d'exactitude en tenant compte de divers facteurs tels que la qualité des données, la préparation des données, les architectures de réseau, et les méthodes de post-traitement. Nous avons également examiné les avantages et les inconvénients de ces approches, tels que leur facilité d'utilisation, leur faible besoin en données, leur efficacité de l'entraînement, leur complexité de modèle, leur interprétabilité et leur coût

Cette étude comparative nous permet de mieux comprendre l'état actuel de la recherche sur la détection et la classification des mélanomes et nous fournit des orientations pour la conception de futures approches de deep learning pour résoudre ce problème.

### 3.4 Conclusion

En conclusion, les études présentées dans cet état de l'art montrent que l'utilisation de l'apprentissage profond pour la détection et la classification du mélanome présente de grands avantages, notamment en termes de performances de diagnostic et de réduction des coûts. Cependant, la qualité et la quantité des données d'entraînement sont des éléments critiques pour l'obtention de résultats précis et fiables. De plus, il est crucial de s'assurer que les modèles sont interprétables et robustes, afin d'assurer leur adoption dans la pratique clinique. Les recherches futures devront explorer des techniques telles que la segmentation d'image et la fusion de données multimodales pour améliorer davantage les performances des modèles.

# Chapitre 4

## Approche proposée

### 4.1 Introduction

Le mélanome, une forme redoutable de cancer de la peau, se trouve au centre de notre étude. Dans une époque où l'information précise et les diagnostics rigoureux sont d'une importance capitale, il est crucial d'adopter des approches objectives pour appréhender ce fléau cutané. C'est dans cette perspective que nous nous engageons dans une approche novatrice, visant à prédire le mélanome grâce à une analyse approfondie des données médicales disponibles. Tout en reconnaissant la sensibilité inhérente à ce sujet, nous mettrons en lumière les éléments clés à prendre en considération, ainsi que les défis complexes liés à la recherche d'une détection précoce et d'une compréhension approfondie de cette menace insidieuse. Ce chapitre exposera en détail l'approche méthodique que nous avons adoptée tout au long de notre projet, en mettant en avant les différentes étapes qui ont abouti à la prédiction du mélanome à partir des données médicales.

### 4.2 Disséquer notre approche en détail

Notre projet se concentre sur la prédiction précoce des risques liés au mélanome, une forme sévère de cancer de la peau, en utilisant des images dermatologiques. L'objectif est d'offrir aux individus la possibilité de déterminer s'ils courent le risque de développer un mélanome à un stade initial, avec un taux de prédiction précis. La mise en œuvre de ce projet nécessite plusieurs étapes cruciales pour garantir la précision et la fiabilité des prédictions. Ces étapes comprennent la collecte d'images, leur prétraitement, la sélection du modèle, l'entraînement, l'évaluation du modèle, et enfin la combinaison des différents modèles pour une prédiction optimale.

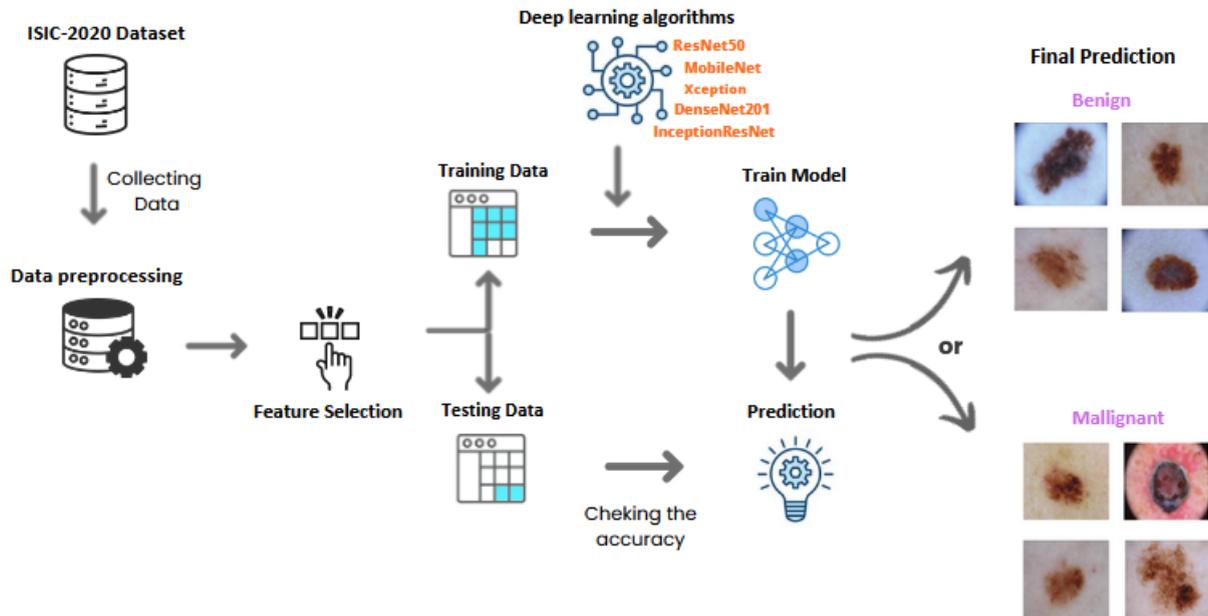


FIGURE 4.1 – La stratégie adoptée et les différentes étapes qui la constituent.

La Figure 4.1 représente la stratégie choisie. Voici un aperçu détaillé des différentes étapes qui la composent :

La première étape consiste à importer un ensemble d’images dermatologiques depuis une source fiable. Lors du prétraitement, les images sont adaptées et normalisées pour l’analyse, et un redimensionnement est effectué pour assurer une uniformité des tailles. Il est à noter que notre ensemble de données est déjà divisé en données d’entraînement et de test.

Pour la phase de modélisation, nous avons exploré plusieurs modèles de transfer learning, tels que ResNet50, DenseNet121, InceptionResnet, Xception, MobileNet. Chaque modèle est ensuite entraîné avec l’ensemble d’entraînement. Après l’entraînement, chaque modèle est évalué individuellement sur sa capacité à identifier les signes précoces du mélanome à l’aide des données de test. Suite à ces évaluations, nous adoptons une approche d’ensemble learning, combinant les forces de chaque modèle pour améliorer encore la précision des prédictions. En fusionnant les outputs des différents modèles, nous visons une prédiction plus robuste et fiable du risque de mélanome.

### 4.2.1 Collecte des données

La collecte des données est une étape fondamentale dans le processus de prédiction du mélanome. L’importance d’un dataset robuste et fiable ne saurait être sous-estimée pour garantir une analyse pertinente. Dans le cadre de ce projet, nous utilisons un extrait du ISIC 2020 [103], une base de données renommée pour les images dermatologiques liées au mélanome. Ce dataset a été enrichi grâce aux contributions de plusieurs établissements médicaux de renom à travers le monde, dont l’Hôpital Clinique de Barcelone, l’Université Médicale de Vienne, le Centre de Cancer Memorial Sloan Kettering, l’Institut du Mélanome d’Australie, l’Université du Queensland et l’École Médicale de l’Université d’Athènes. [49] Grâce à cette diversité institutionnelle, notre dataset présente un panorama complet et détaillé des différentes manifestations du mélanome. L’objectif majeur de cette collecte est d’assurer que nous disposons

d'un ensemble de données diversifié et authentique, essentiel pour élaborer et valider des modèles prédictifs solides. Chaque image, chaque information, contribue à renforcer la base sur laquelle repose notre analyse, optimisant ainsi la précision de nos prédictions en matière de mélanome.

### 4.2.2 Prétraitement

Après la collecte des images liées au mélanome, l'étape cruciale qui suit est celle du prétraitement. Cette phase est déterminante pour obtenir un dataset optimisé, essentiel pour des analyses précises et des résultats fiables. Même dans des datasets de grande qualité comme ceux issus du ISIC, certaines images peuvent présenter des anomalies, des artefacts ou des variations dues à l'éclairage, à l'angle de prise de vue ou à d'autres facteurs. Si ces imperfections ne sont pas traitées, la qualité des résultats de prédiction peut être compromise.

Le prétraitement des images pour le mélanome englobe plusieurs sous-étapes :

- **Exploration et visualisation des images**

La richesse du dataset ISIC réside en grande partie dans la diversité des lésions qu'il contient. En parcourant et en visualisant les images, on peut distinguer une variété de lésions cutanées, des plus bénignes aux mélanomes malins. Cette diversité offre une opportunité unique d'entraîner des modèles de machine learning avec une gamme complète de manifestations dermatologiques, permettant ainsi une meilleure généralisation et une détection précoce des anomalies. On peut constater que :

- Répartition du dataset :
  - Divisé en deux sous-ensembles :
    - Entraînement (train).
    - Test.
- Données d'entraînement :
  - Deux classes :
    - Classe maligne : 4 605 images.
    - Classe bénigne : 5 000 images.
- Données de test :
  - Deux classes :
    - Classe maligne : 500 images.
    - Classe bénigne : 500 images.

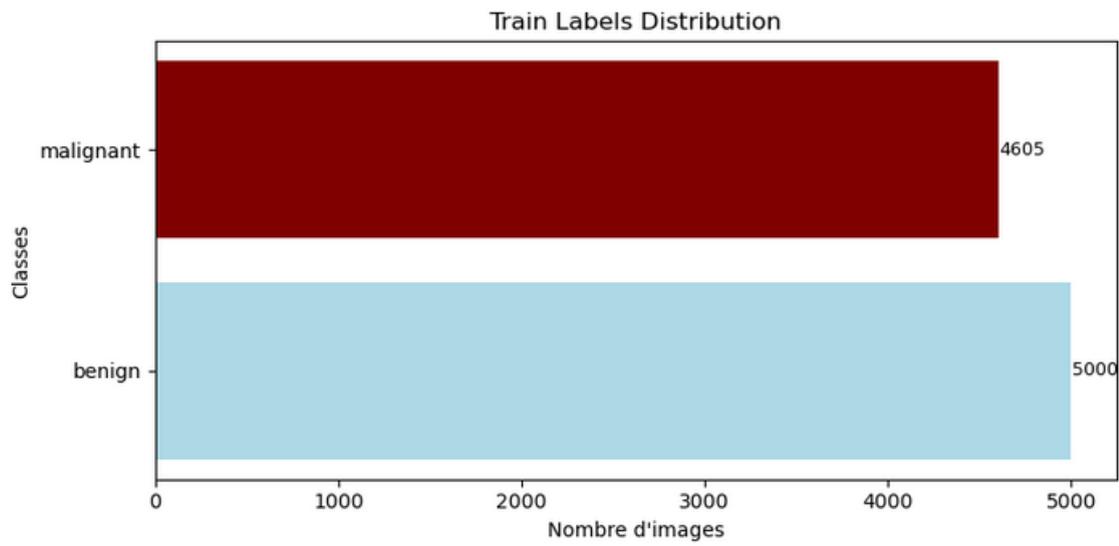


FIGURE 4.2 – Distribution des données d'entraînement par Classe.

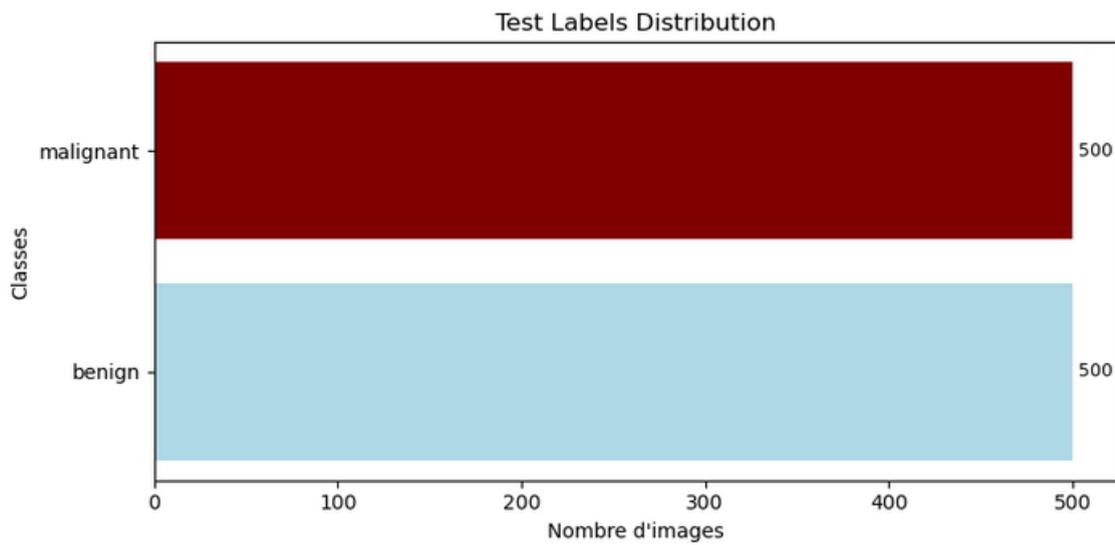


FIGURE 4.3 – Distribution des données de test par Classe.

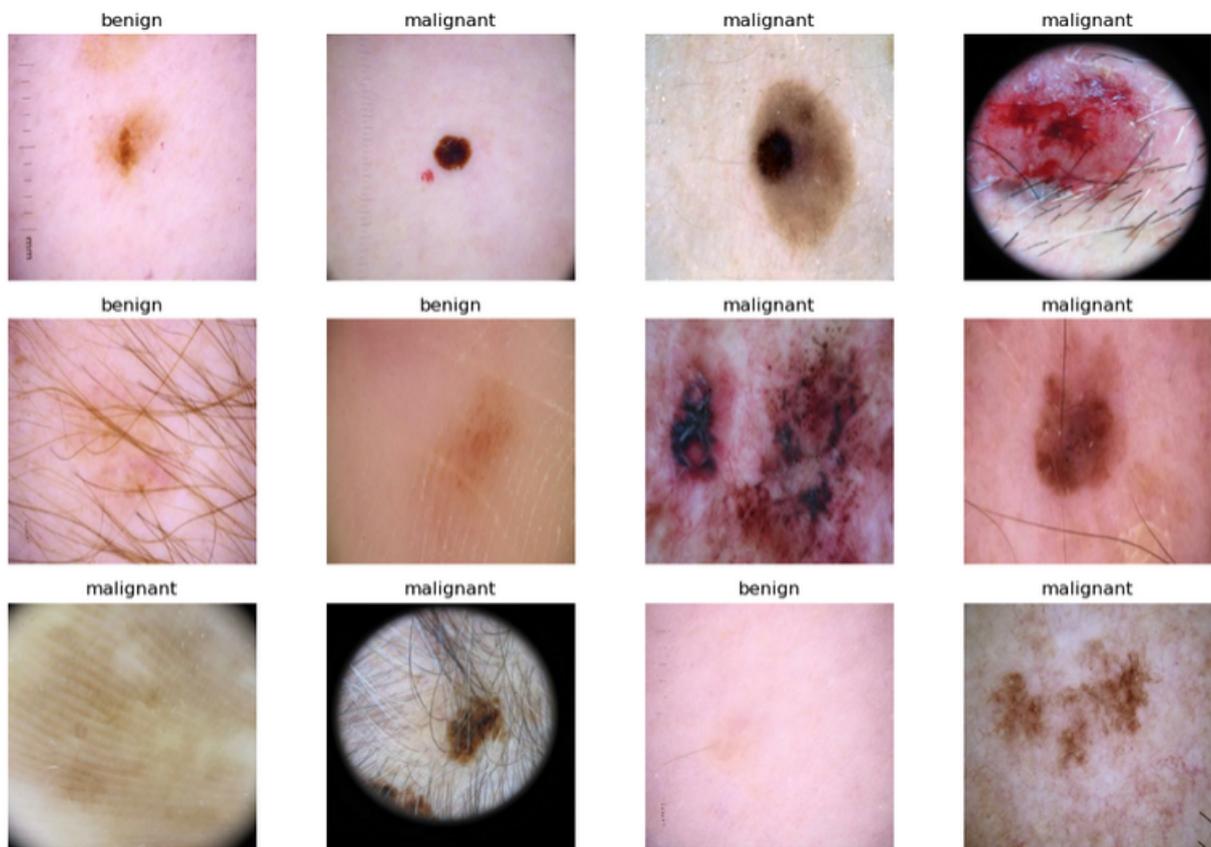


FIGURE 4.4 – Aperçu visuel de l'ensemble de données.

— **Gérer le déséquilibre des classes dans un jeu de données**

Dans le domaine de la classification en Machine Learning, il est courant de rencontrer des datasets déséquilibrés. Un dataset est considéré comme déséquilibré lorsque le ratio des observations d'une classe par rapport à l'ensemble des observations est très faible. Ce phénomène est fréquemment observé dans divers secteurs tels que le médical ou le bancaire. Plusieurs méthodes ont été développées pour pallier ce déséquilibre. Parmi les méthodes "data-level", on trouve le sous-échantillonnage aléatoire, les "tomek links" et SMOTE (Synthetic Minority Oversampling Technic). Ces techniques visent à transformer les données d'entraînement pour réduire le déséquilibre. D'un autre côté, les méthodes "algorithm-level" adaptent les modèles de machine learning pour mieux gérer le déséquilibre. L'apprentissage sensible aux coûts, par exemple, attribue un poids plus important à la classe minoritaire. Il est également crucial de choisir des métriques appropriées pour évaluer les performances des modèles sur des données déséquilibrées. [50]

Dans notre contexte spécifique, nous observons un certain déséquilibre dans notre dataset : nous avons 5000 observations classées comme "malignes" et 4605 comme "bénignes". Bien que ce déséquilibre ne soit pas extrême, il peut néanmoins influencer les performances de nos modèles de machine learning. Afin de garantir des prédictions plus précises et d'améliorer la robustesse de nos modèles, il est indispensable d'effectuer un prétraitement adapté. Dans notre cas, nous opterons pour le sous-échantillonnage de la classe "maligne" pour équilibrer les deux classes à 4605 observations chacune. Cette approche est reconnue pour sa capacité à clarifier les frontières entre les classes et à renforcer la performance des modèles.

Après l'équilibrage :

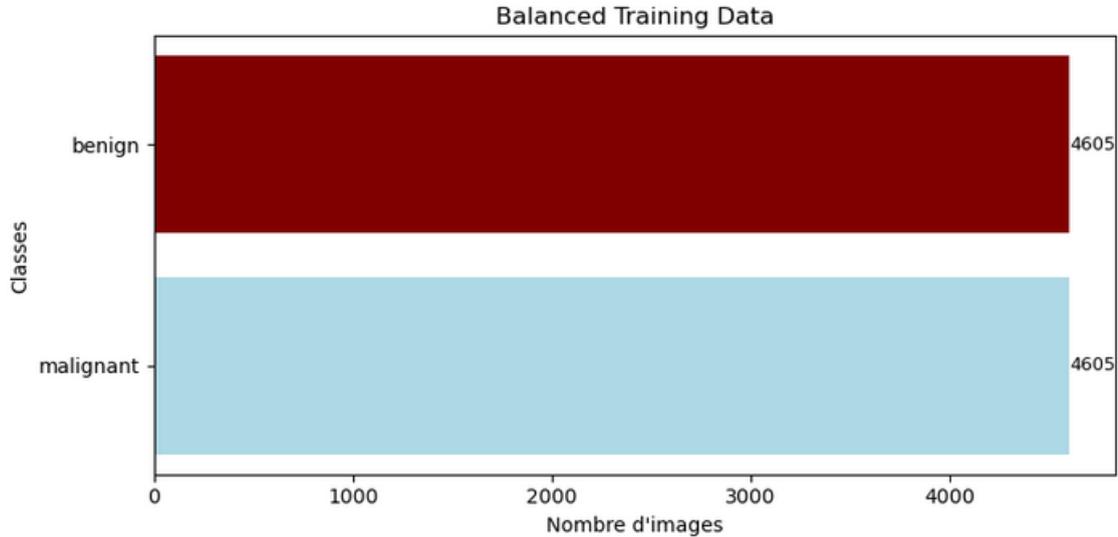


FIGURE 4.5 – Distribution des données d'entraînement par classe après le sous-échantillonnage

## — Division de l'Ensemble d'Entraînement en NewTrain et Validation

Lors de la mise au point de modèles d'apprentissage automatique destinés à la détection du mélanome, il est essentiel de bien structurer et répartir les données. En particulier, distinguer les échantillons de mélanomes malignes de ceux qui sont bénins est crucial pour la précision du modèle.

À partir de notre jeu de données initial, déjà divisé en ensembles d'entraînement et de test, une étape supplémentaire est réalisée : la subdivision de l'ensemble d'entraînement en deux sous-ensembles, "newtrain" et "valid".

**Train set ("newtrain") :** Cet ensemble est dédié à l'entraînement du modèle, permettant d'ajuster ses paramètres pour mieux comprendre les nuances entre mélanomes malignes et bénins. [52]

**Valid set :** Une fois l'entraînement initial terminé, cet ensemble est utilisé pour affiner le modèle, évaluant ses performances sur des données non vues. Il permet de comparer différentes configurations ou versions du modèle pour en sélectionner la meilleure, sans introduire de biais. [52]

**Test set :** Cet ensemble, distinct des deux précédents, sert à évaluer le modèle dans des conditions proches de la réalité, sur des données qu'il n'a jamais vues. [52]

### Démarche suivie :

1. Définition de la taille de l'ensemble de validation (`valid_size`) à 10% de l'ensemble d'entraînement.
2. Calcul du nombre exact d'échantillons nécessaires (`valid_number`) pour l'ensemble de validation.
3. Mélange aléatoire des échantillons pour garantir une distribution homogène.
4. Répartition des échantillons selon le `valid_number` pour créer les ensembles de validation et d'entraînement, tant pour les mélanomes malins que bénins.

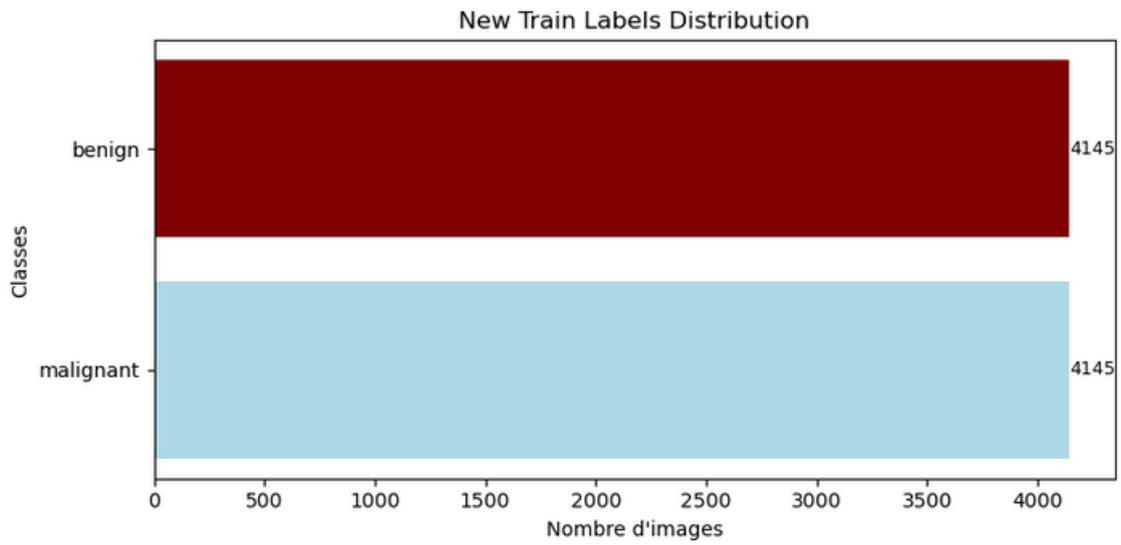


FIGURE 4.6 – Distribution par classe du nouvel ensemble d’entraînement après la division.

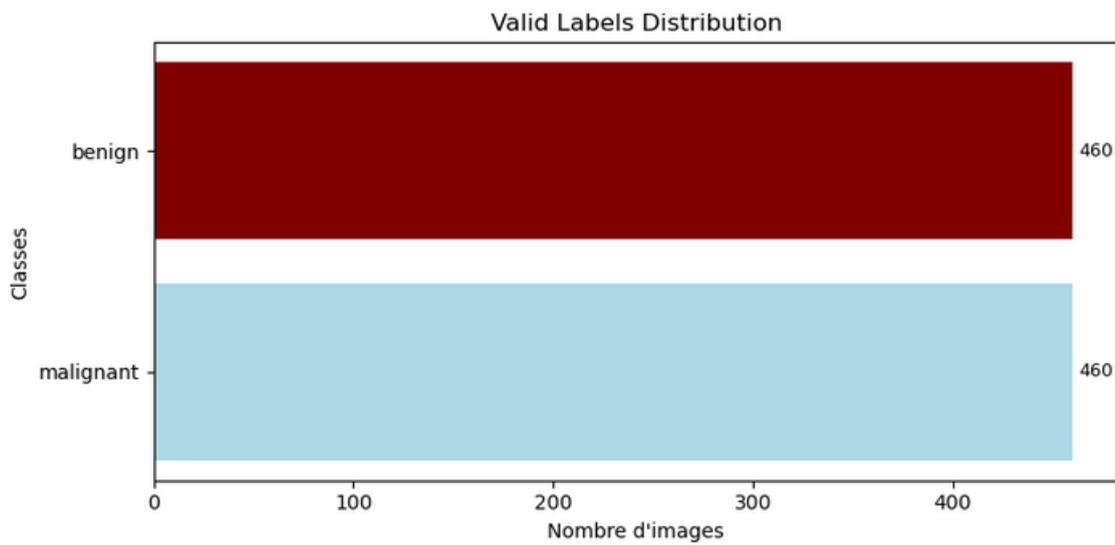


FIGURE 4.7 – Distribution par classe de l’ensemble de validation après la division.

### — Ajustement de la Dimension des Images pour l'Uniformité (Redimensionnement)

L'adaptation et l'ajustement des modèles pré-entraînés pour des cas d'utilisation spécifiques sont essentiels lorsqu'il s'agit de tirer le meilleur parti des réseaux neuronaux convolutionnels (CNN). Dans de nombreux scénarios, le défi réside dans la gestion des différentes dimensions des images par rapport à celles sur lesquelles un modèle a été initialement formé.

Par exemple, PyImageSearch fournit des indications précieuses sur la manière de changer les dimensions du tenseur d'entrée lorsque l'on travaille avec Keras, particulièrement en ce qui concerne l'application du transfer learning. Cette méthode s'avère pertinente lors du traitement d'images dont les tailles diffèrent de celles sur lesquelles le CNN a été formé initialement. Assurer la concordance des tailles d'images est implicitement conseillé afin de garantir une compatibilité optimale avec le modèle. [53]

Dans ce contexte, considérons notre propre cas : notre dataset est constitué d'images de taille 300x300. Cependant, nous faisons face à un défi, car tous les modèles que nous avons sélectionnés pour notre travail ont une taille d'entrée standard de 224x224 ou de 299x299. Cette disparité souligne l'importance d'ajuster soigneusement nos images à la taille attendue par le modèle, pour assurer de bons résultats.

```
img_height = 224
img_width = 224
batch_size_16 = 16
train_ds = tf.keras.utils.image_dataset_from_directory(
    train_dir,
    image_size=(img_height, img_width),
    batch_size=batch_size_16)

valid_ds = tf.keras.utils.image_dataset_from_directory(
    valid_dir,
    image_size=(img_height, img_width),
    batch_size=batch_size_16)
```

Found 8290 files belonging to 2 classes.  
Found 920 files belonging to 2 classes.

FIGURE 4.8 – Chargement et redimensionnement des images.

### — Augmentation des données

Lorsqu'on dispose d'un ensemble de données d'images limité, il est recommandé d'introduire de la variabilité artificielle dans les échantillons d'entraînement en utilisant des transformations aléatoires spécifiques, notamment :

- Renversement horizontal aléatoire.
- Légères rotations aléatoires.
- Zoom aléatoire.
- Contraste aléatoire.
- Luminosité aléatoire.

Ces transformations visent à exposer le modèle à une diversité d'aspects des données d'entraînement, réduisant ainsi le risque de surapprentissage. [99]

```
data_augmentation = keras.Sequential(  
    [  
        layers.RandomFlip("horizontal"),  
        layers.RandomRotation(0.2),  
        layers.RandomZoom(0.2),  
        layers.RandomContrast(0.2),  
        layers.RandomBrightness(0.2),  
    ]  
)
```

FIGURE 4.9 – Les différentes augmentations de données utilisées.

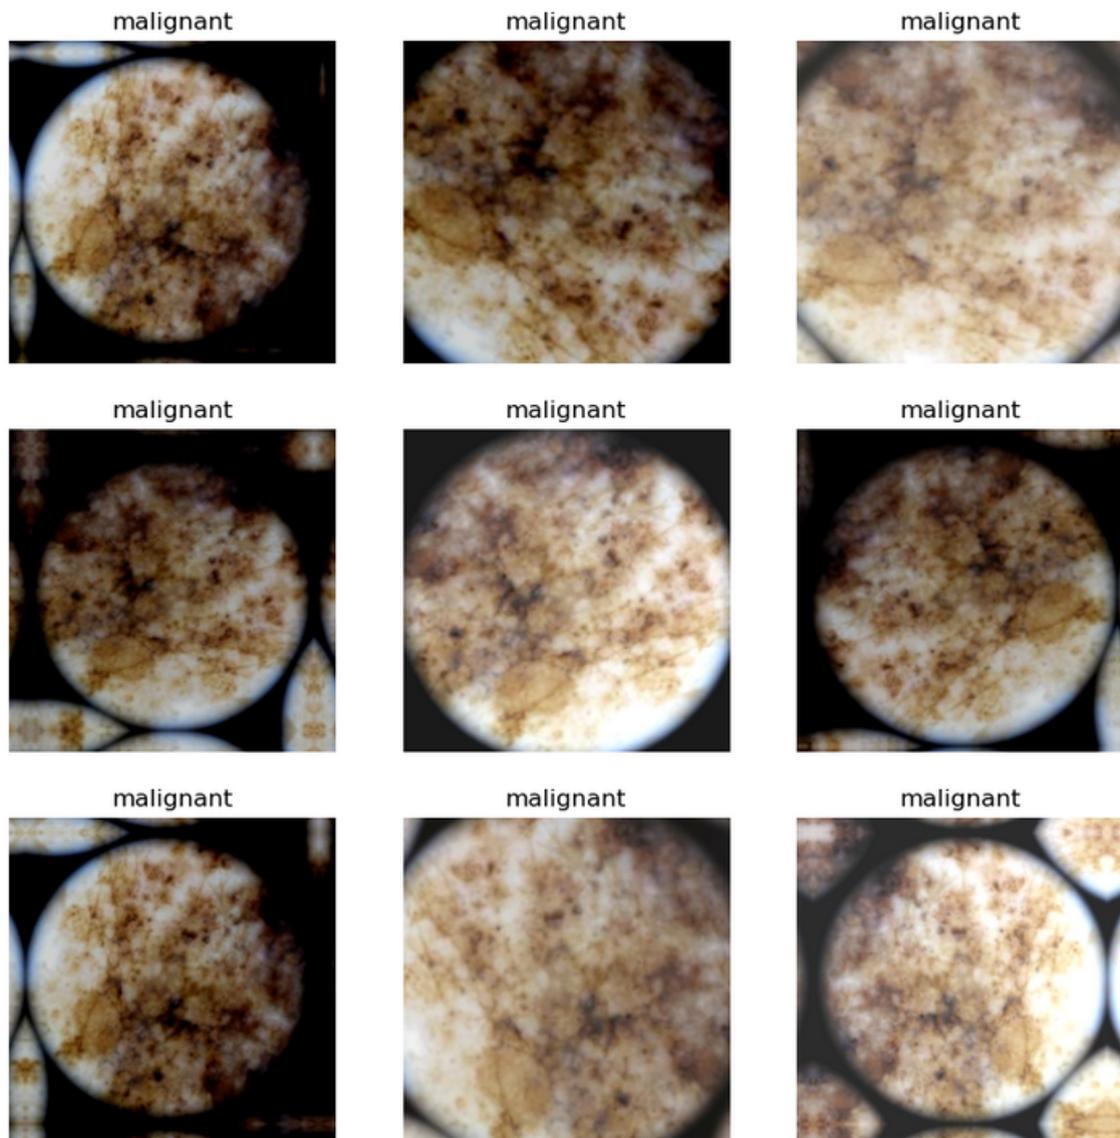


FIGURE 4.10 – Visualisation des Résultats de l'Augmentation des Images.

### — La Normalisation des Images

Selon la documentation de Keras sur les couches de prétraitement, la normalisation des images est une étape essentielle pour standardiser les entrées d'un modèle d'image. La couche `tf.keras.layers.Rescaling` redimensionne et décale les valeurs d'un lot d'images. Par exemple, pour transformer des entrées dans la plage  $[0, 255]$  en entrée dans la plage  $[0, 1]$ , la couche `Rescaling` est utilisée. Ces étapes garantissent que les images sont traitées de manière uniforme avant d'être introduites dans un modèle, assurant ainsi une meilleure performance et une convergence plus rapide lors de l'entraînement.

## 4.3 Choix des architectures CNN pour la classification

Suite au prétraitement des données, nous abordons l'étape cruciale de la sélection de modèles en vue de classer le mélanome. Dans ce contexte, nous avons décidé de faire appel aux techniques de transfert d'apprentissage, l'une des méthodologies les plus prometteuses en matière de classification d'images. Cette technique présente des avantages significatifs, en particulier pour des situations où les données sont limitées ou spécifiques.

À partir de ce point, il serait pertinent d'approfondir le concept du *transfer learning* pour mieux en saisir les nuances et les avantages.

### 4.3.1 Transfer learning

Le *transfer learning* est une méthode d'apprentissage automatique où un modèle développé pour une tâche est réutilisé comme point de départ pour un modèle sur une deuxième tâche. C'est une approche populaire en apprentissage profond où des modèles pré-entraînés sont utilisés comme point de départ pour des tâches de vision par ordinateur et de traitement du langage naturel, étant donné les vastes ressources de calcul et de temps nécessaires pour développer des modèles de réseaux neuronaux sur ces problèmes. L'avantage de cette méthode est qu'elle permet d'exploiter les connaissances acquises lors de la première tâche pour améliorer les performances sur une tâche connexe. Cela est particulièrement utile lorsque les ressources pour entraîner un modèle à partir de zéro sont limitées. En utilisant un modèle pré-entraîné, il est possible d'accélérer la formation et de potentiellement obtenir de meilleures performances. [54]

## TRANSFER LEARNING

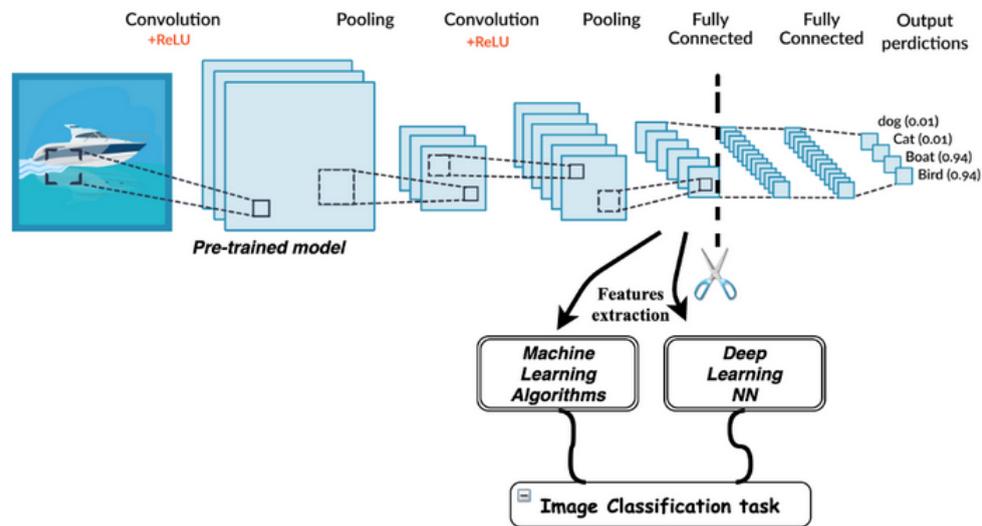


FIGURE 4.11 – Un Regard graphique sur le transfert d’apprentissage. [55]

En tenant compte de cette approche, nous avons sélectionné cinq modèles issus du transfer learning. Notre objectif est de les combiner ultérieurement pour adopter une stratégie d’ensemble learning, améliorant ainsi la précision de la classification du mélanome. Les modèles retenus sont :

### 4.3.2 ResNet-50

ResNet-50 est un réseau neuronal convolutif qui comporte 50 couches, dont 48 sont des couches de convolution, accompagnées d’une couche MaxPool et d’une couche Average Pool. [56] Il s’agit d’un type particulier de réseau résiduel, qui utilise des connexions directes entre certaines couches pour éviter le problème du gradient qui s’évanouit. ResNet-50 a été entraîné sur plus d’un million d’images de la base de données ImageNet, et peut classer les images en 1000 catégories d’objets, comme le clavier, la souris, le crayon, et de nombreux animaux. ResNet-50 utilise une conception en entonnoir pour ses blocs résiduels, qui réduit le nombre de paramètres et de multiplications matricielles. Il utilise une pile de trois couches plutôt que deux couches pour chaque bloc résiduel. ResNet-50 a une taille d’entrée d’image de 224 par 224 pixels. [57]

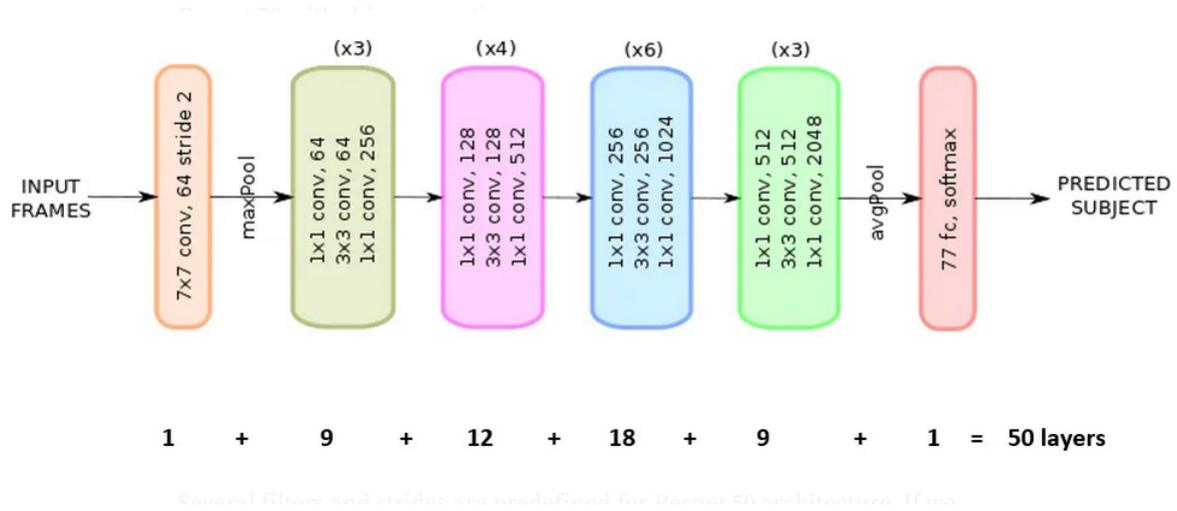


FIGURE 4.12 – Analyse complète de l’architecture ResNet-50. [56]

### 4.3.3 DenseNet-201

DenseNet est une architecture de réseau neuronal convolutif (CNN) introduite en 2016 par Gao Huang, Zhuang Liu, Laurens van der Maaten et Kilian Q. Weinberger. Une des variantes de cette architecture est la DenseNet-201, qui comporte 201 couches. C’est une architecture de pointe qui a obtenu des performances exceptionnelles dans les tâches de classification d’images. La taille d’entrée des images pour cette architecture est généralement de 224\*224. [58] DenseNet signifie "Densely Connected Convolutional Networks", et il porte ce nom parce qu’il connecte chaque couche à toutes les autres couches de manière feedforward. DenseNet a deux caractéristiques principales qui le distinguent des autres architectures CNN. Premièrement, il possède une structure de bloc dense, où chaque couche est connectée à toutes les autres couches de manière feedforward. Deuxièmement, il utilise des couches goulot d’étranglement qui aident à réduire le nombre de paramètres sans réduire le nombre de caractéristiques apprises par le réseau. [59]

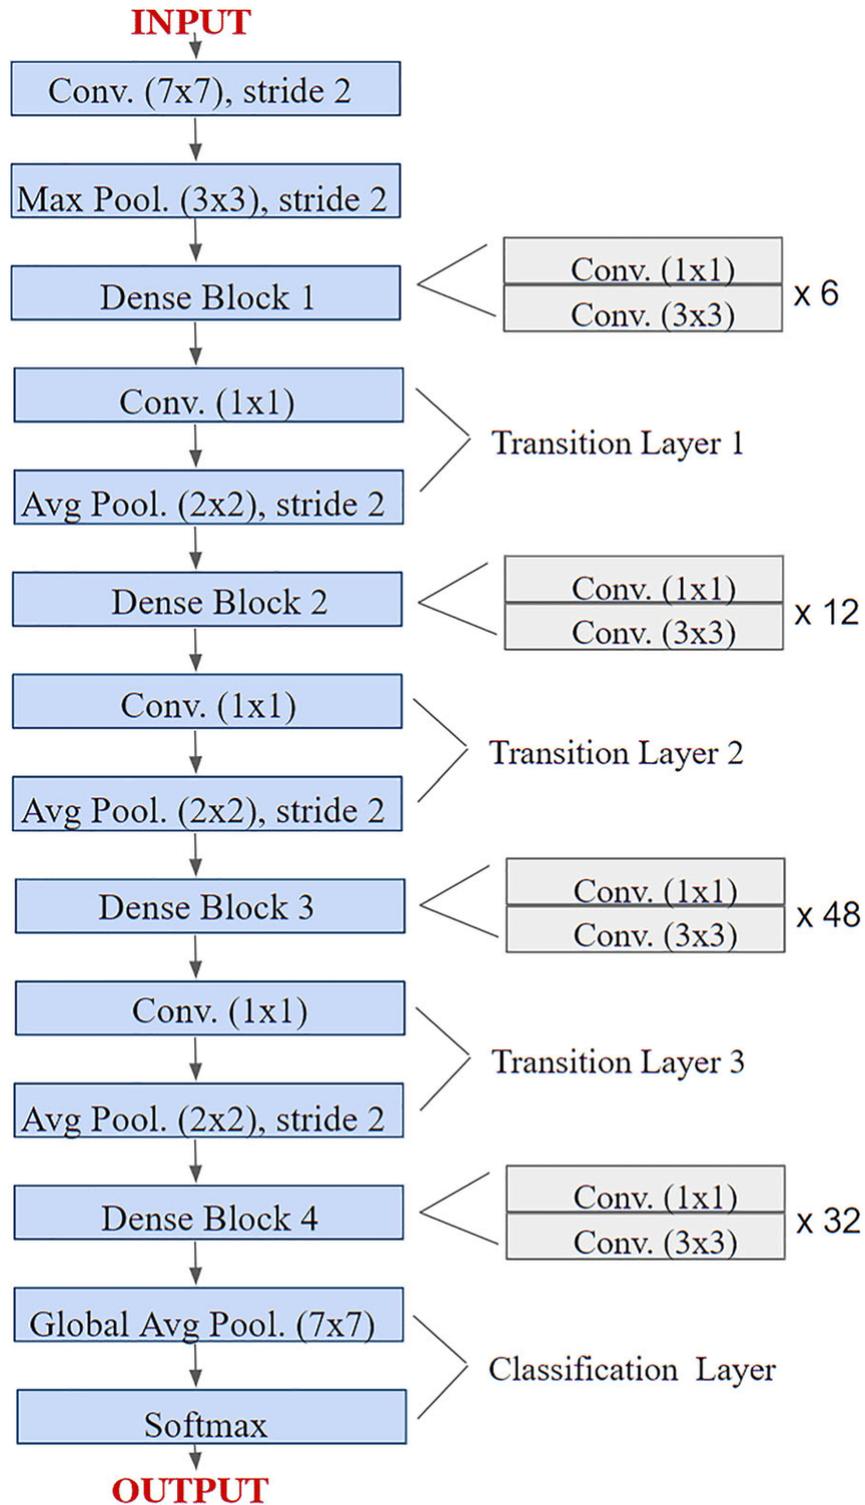


FIGURE 4.13 – Analyse complète de l’architecture DenseNet-201. [60]

### 4.3.4 InceptionResNetV2

Inception-ResNet-v2 est un réseau de neurones convolutionnels qui combine les architectures "Inception" et "ResNet", avec des améliorations par rapport aux versions précédentes, pour la classification d'images. Ce réseau a été entraîné sur plus d'un million d'images de la base de données ImageNet [1]. Il compte 164 couches et est capable de classer des images dans 1000 catégories d'objets différentes. Par conséquent, le réseau a appris des représentations de caractéristiques riches pour un large éventail d'images. Sa taille d'entrée d'image est de 299 par 299. [61]

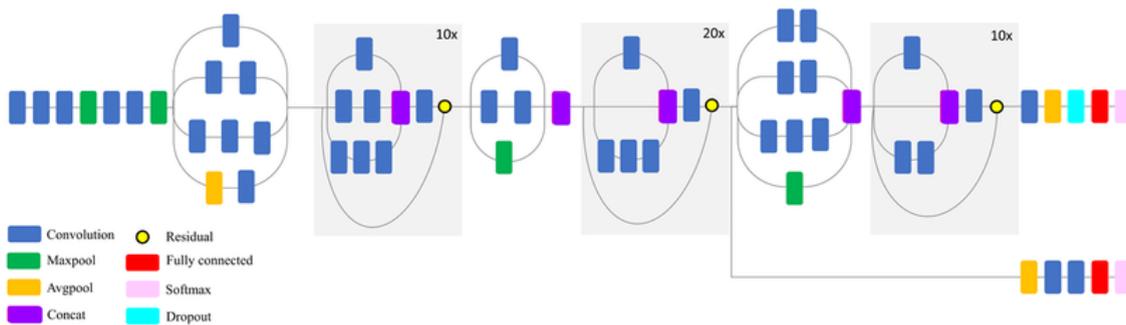


FIGURE 4.14 – Analyse complète de l'architecture InceptionResNetV2. [62]

### 4.3.5 Xception

Le nom "Xception" a été choisi pour ce réseau de neurones convolutionnels en combinant les mots "Extreme" (extrême) et "Perception" (perception). Il s'agit d'un réseau composé de 71 couches, et une version pré-entraînée peut être chargée, ayant été formée sur plus d'un million d'images de la base de données ImageNet [1]. Cette version pré-entraînée a la capacité de classer des images dans 1000 catégories d'objets différentes. Cette capacité résulte de l'apprentissage par le réseau de représentations de caractéristiques riches pour une grande variété d'images. La taille d'entrée des images que ce réseau peut traiter est de 299 par 299 pixels. [63] [64]

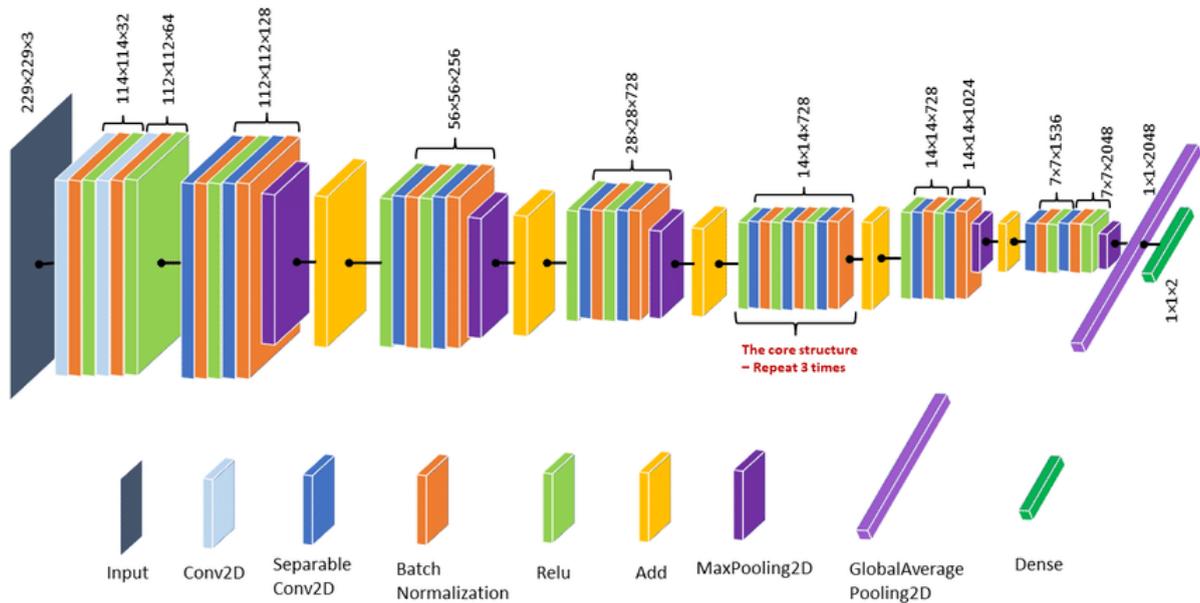


FIGURE 4.15 – Analyse complète de l'architecture Xception. [66]

### 4.3.6 MobileNet

MobileNet est un modèle de vision par ordinateur introduit par Google en 2017. Basé sur une architecture optimisée, il utilise des convolutions séparables en profondeur pour construire des réseaux neuronaux profonds légers. Cette architecture particulière permet à MobileNet d'être plus efficace en termes de calcul et de taille, ce qui le rend idéal pour les applications mobiles et les dispositifs à ressources limitées. En ce qui concerne la taille des images en entrée, MobileNet est flexible et peut traiter différentes résolutions, bien que 224x224 pixels soit couramment utilisée. Le nom "MobileNet" reflète l'objectif principal de cette architecture : fournir un réseau neuronal de haute performance adapté aux appareils mobiles. Le nom souligne sa capacité à fonctionner sur des dispositifs avec des contraintes de ressources tout en conservant une performance de vision par ordinateur de haute qualité. [65]

## 4.4 Wisdom of Crowds

La sagesse des foules, ou "the wisdom of crowds", est un concept sociologique qui postule que la collectivité d'un grand groupe de personnes est souvent plus apte à prendre des décisions précises que même le plus érudit des experts individuels. Cette théorie repose sur l'idée que la diversité des opinions au sein d'une foule permet de neutraliser les biais individuels, conduisant ainsi à une meilleure précision globale. James Surowiecki a popularisé cette notion dans son livre "The Wisdom of Crowds", où il démontre que sous certaines conditions, les groupes sont remarquablement intelligents et sont souvent plus intelligents que l'individu le plus intelligent du groupe. Pour que la sagesse des foules soit efficace, plusieurs critères doivent être respectés :

- **Taille adéquate** : La foule doit être suffisamment grande. [81]
- **Diversité des opinions** : Chaque membre de la foule devrait apporter une perspective ou une information qui lui est propre, garantissant ainsi une riche diversité d'opinions. [81]

- **Compétence** Les membres de la foule doivent posséder une certaine compétence, avec idéalement au moins 50% d'entre eux ayant une expertise ou une capacité à évaluer l'information à sa juste valeur. [81]

#### 4.4.1 Ensemble learning

L'ensemble learning, s'inspirant du concept de "the wisdom of the crowds" (sagesse des foules), est une technique avancée d'intelligence artificielle qui intègre plusieurs algorithmes de machine learning afin d'améliorer la puissance prédictive globale. Au lieu de se reposer sur un unique algorithme, il mise sur la synergie de plusieurs modèles. L'essence de cette approche repose sur l'idée qu'une combinaison de modèles, bien qu'ils soient individuellement imparfaits, peut mutualiser leurs forces et neutraliser leurs limites, conduisant ainsi à une prédiction plus stable et fiable. On distingue deux modes d'application de l'ensemble learning : la méthode séquentielle où les modèles sont élaborés l'un après l'autre, chaque nouveau modèle étant adapté pour pallier les lacunes de ses prédécesseurs ; et la méthode parallèle où plusieurs modèles sont entraînés simultanément sur divers segments de données. Leurs prédictions sont alors fusionnées, soit par un mécanisme de vote pour les problématiques de classification, soit par une moyenne pour les problématiques de régression. [82]

Trois techniques principales sont utilisées en ensemble learning :

- **Bagging** : Également appelé bootstrap aggregating, cette méthode parallèle consiste à sous-échantillonner les données, en créant un ensemble de données pour chaque modèle. Le résultat final est déterminé par un vote des résultats de chaque modèle pour une classification, ou par une moyenne pour une régression. [82]
- **Boosting** : Une méthode séquentielle qui combine les modèles classificateurs en les pondérant à chaque nouvelle prédiction. Les modèles ayant prédit correctement ont un poids plus important que les modèles incorrects. [82]
- **Forêt Aléatoire** : Une amélioration du bagging associée au concept de sous-espace aléatoire. Elle crée de multiples arbres de décision, avec des modèles formés sur des sous-ensembles de données légèrement différents. Les échantillons étant créés de manière aléatoire, la corrélation entre les arbres est réduite, conduisant à un meilleur résultat global. [82]

Après avoir minutieusement sélectionné cinq modèles prédictifs, chacun apportant sa propre perspective et expertise, il est temps d'exploiter leur puissance collective pour obtenir des résultats encore plus fiables et précis. Pour ce faire, nous avons choisi d'adopter la technique du vote majoritaire, une approche qui tire parti du concept de la "sagesse des foules".

À travers cette méthode de combinaison, chaque modèle exprime son opinion quant à la prédiction d'un résultat donné. Comme autant de voix dans une assemblée, les modèles individuels émettent leurs prédictions, reflétant ainsi leurs forces et leurs spécificités. Les variations et les erreurs aléatoires propres à chaque modèle tendent à s'équilibrer lorsqu'ils sont soumis au processus de vote.

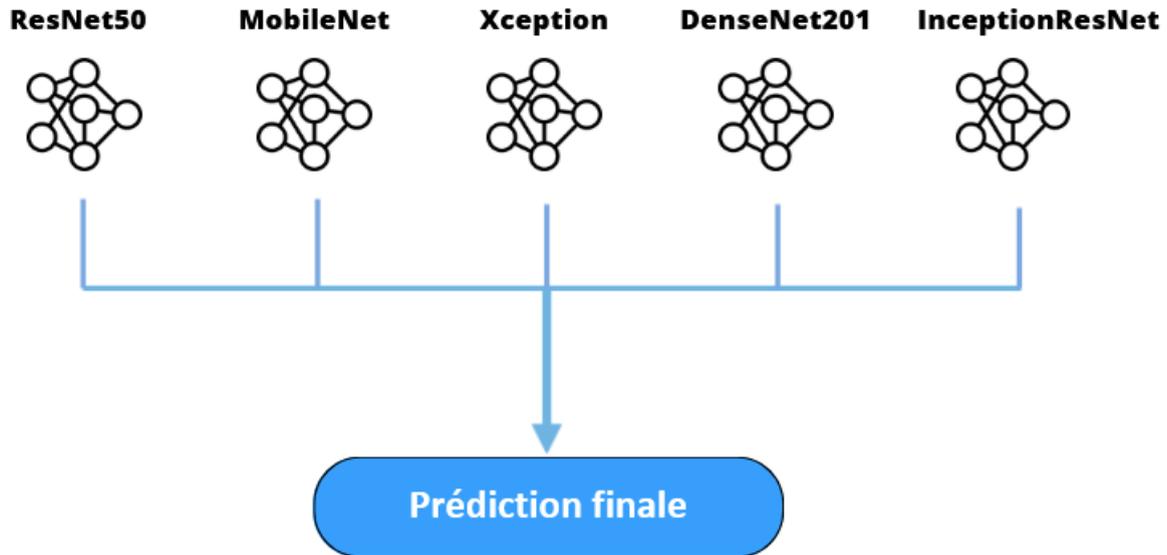


FIGURE 4.16 – illustration du processus de fusion des prédictions par un vote majoritaire.

## 4.5 Conclusion

Dans ce chapitre, nous avons exposé en détail notre méthode de classification du mélanome. Pour ce faire, nous avons opté pour cinq modèles de transfert learning, exploitant leur expertise respective pour améliorer la précision de la prédiction. Notre objectif principal était de capitaliser sur les forces de chaque modèle individuellement, pour ensuite les fusionner en une seule entité puissante grâce à l'ensemble learning.. Cette démarche s'inspire des dernières avancées en matière de classification d'images et vise à offrir des résultats encore plus fiables dans la détection du mélanome. Dans le chapitre suivant, nous détaillerons les aspects techniques et les résultats liés à l'implémentation de notre solution.

# Chapitre 5

## Expérimentation et évaluation

### 5.1 Introduction

Dans le cadre de notre recherche, nous nous sommes concentrés sur l'optimisation de la classification du mélanome à partir de notre ensemble de données d'images. La préparation et le traitement de ces images sont essentiels afin d'assurer une clarté optimale et de gérer les défauts courants qui peuvent affecter un dataset, tels que les données déséquilibrées et les erreurs d'étiquetage.

Ce chapitre aborde les différentes étapes et techniques employées dans notre approche de classification des images. Nous discuterons des défis spécifiques associés à la classification d'images en dermatologie et examinerons la performance des modèles de classification que nous avons sélectionnés. Le chapitre se clôturera sur une synthèse de nos principales découvertes et observations.

### 5.2 Environnement de développement

La mise en œuvre et l'opération du système d'assistance au diagnostic du mélanome en utilisant une vaste base de données comme ISIC-2020 Archive nécessitent un équipement performant. Pour cela, nous avons choisi la plateforme Kaggle. Non seulement Kaggle donne un accès gratuit aux GPU NVIDIA TESLA P100 pendant 30 heures chaque semaine, mais elle permet également un accès direct à la base de données sans la contrainte d'importation. Les GPU (Unités de Traitement Graphique) sont essentiels pour optimiser la durée d'apprentissage des réseaux neuronaux en raison de leur aptitude à traiter efficacement les multiplications et les calculs liés aux matrices et vecteurs. Avec les GPU, l'apprentissage des réseaux neuronaux peut être accéléré jusqu'à 100 fois, même si la vitesse exacte dépend de divers facteurs, tels que la structure du réseau ou la taille du lot de données...etc



FIGURE 5.1 – Logo de kaggle. [100]

### 5.2.1 Langage de programmation

- **Python** Python est un langage de programmation open source de haut niveau, largement plébiscité pour sa lisibilité et son orientation objet. Sa popularité auprès des informaticiens et des développeurs s’explique en grande partie par sa polyvalence, notamment dans les domaines des applications Web, du développement de logiciels et de la science des données. En ce qui concerne le deep learning et le machine learning, Python se distingue par sa capacité à offrir une puissance exceptionnelle tout en s’intégrant facilement avec divers outils et bibliothèques. Sa simplicité et sa facilité d’apprentissage, associées à un code clair et compréhensible, en font le choix privilégié pour le développement de modèles complexes. En somme, Python est non seulement reconnu pour ses capacités techniques, mais aussi pour sa facilité d’utilisation, ce qui le rend incontournable dans le domaine du deep learning. [79] [80]



FIGURE 5.2 – Logo de python. [89]

### 5.2.2 Bibliothèques de Python

Python est un langage de programmation populaire en grande partie grâce à ses nombreuses bibliothèques. Ces collections de fonctions et de modules aident les développeurs à accomplir des tâches sans avoir à tout écrire depuis zéro. Que ce soit pour les mathématiques, le web ou la manipulation de données, il y a probablement une bibliothèque Python pour ça. Voici quelques-unes des bibliothèques Python les plus importantes utilisées dans ce projet :

- **Pandas** Pandas est une bibliothèque Python essentielle pour la manipulation et l’analyse de données. Elle est particulièrement utile pour le traitement de données tabulaires et de séries temporelles. La bibliothèque offre des structures de données robustes comme le DataFrame pour stocker des données dans un format tabulaire et la Série pour les données unidimensionnelles. Pandas excelle dans la manipulation de données, permettant des opérations telles que le tri, le filtrage, et l’agrégation avec une grande facilité. De plus, elle offre des fonctionnalités d’importation et d’exportation flexibles, supportant divers formats de fichiers comme CSV, Excel, et SQL. [81]



FIGURE 5.3 – Logo de pandas. [88]

- **Matplotlib** Matplotlib est la principale bibliothèque de création de graphiques en Python, largement utilisée pour créer divers types de visualisations. Elle est rapide et peut exporter vers plusieurs formats d'image, notamment PDF, SVG, JPG, PNG, BMP et GIF. Matplotlib prend en charge divers types de graphiques, notamment les graphiques linéaires, les graphiques de dispersion, les histogrammes, les graphiques à barres, les graphiques d'erreur, les graphiques circulaires et les graphiques en 3D. Elle sert de base à d'autres bibliothèques Python telles que Pandas et Seaborn, simplifiant leur accès aux fonctionnalités de Matplotlib. Fondée par John Hunter en 2002, Matplotlib a vu le jour lors d'une étude postdoctorale en neurobiologie pour la visualisation des données de l'électrocorticographie (ECoG). [93]



FIGURE 5.4 – Logo de matplotlib. [86]

- **Seaborn** Seaborn est une bibliothèque de visualisation de données en Python qui est construite sur Matplotlib. Elle est conçue pour créer des graphiques statistiques attrayants et informatifs avec peu d'effort. Seaborn offre une variété de types de graphiques pour la visualisation de données statistiques, y compris des histogrammes, des graphiques à barres et des graphiques de chaleur. Elle fournit également des thèmes et des palettes de couleurs pour améliorer l'esthétique des graphiques. Seaborn est donc un excellent outil pour toute personne intéressée par la visualisation de données statistiques. [83]



FIGURE 5.5 – Logo de seaborn. [83]

- **NumPy** NumPy, qui signifie "Numerical Python", est le package fondamental pour le calcul scientifique avec Python. Il offre une gamme complète de fonctions mathématiques, de générateurs de nombres aléatoires et d'outils d'algèbre linéaire. Conçu spécifiquement pour travailler avec des tableaux, NumPy est essentiel pour effectuer des opérations sur des matrices et des tableaux multidimensionnels. En plus de sa capacité à gérer des tableaux, NumPy fournit également des fonctions pour travailler dans le domaine de l'algèbre linéaire, de la transformée de Fourier, et bien plus encore. C'est un outil open-source qui est devenu la pierre angulaire de nombreuses autres bibliothèques scientifiques en Python. Grâce à sa haute performance et à sa facilité d'utilisation, NumPy est largement utilisé dans la communauté scientifique et de la science des données pour traiter et analyser des données numériques. [90][91]
- **TensorFlow** TensorFlow est une bibliothèque open source de Machine Learning créée par Google en 2011 sous le nom de DistBelief, elle a été renommée TensorFlow en 2015. Elle permet de développer et d'exécuter des applications de Machine Learning et Deep Learning. La bibliothèque fonctionne avec des graphiques où les nœuds représentent des opérations mathématiques et les bordures des données appelées tensors. L'API de



FIGURE 5.6 – Logo de numpy. [87]

TensorFlow est basée sur Python, mais l'exécution se fait en C++ haute-performance. Ses avantages incluent la facilité d'implémentation et la visualisation via TensorBoard, mais elle présente aussi des inconvénients comme des variations dans les modèles entraînés sur différents systèmes. [92]



FIGURE 5.7 – Logo de tensorflow. [87]

- **Keras** Keras est une bibliothèque open source écrite en Python, principalement basée sur les travaux du développeur de Google, François Chollet, dans le cadre du projet ONEIROS (Open-ended Neuro-Electronic Intelligent Robot Operating System). Elle a été publiée pour la première fois le 28 mars 2015. L'objectif principal de Keras est de faciliter la création rapide de réseaux neuronaux. Elle ne fonctionne pas comme un framework autonome, mais plutôt comme une interface de programmation applicative (API) pour accéder et programmer différents frameworks d'apprentissage automatique, tels que Theano, Microsoft Cognitive Toolkit (anciennement CNTK) et TensorFlow. Depuis la sortie de TensorFlow 1.4, Keras est intégré à l'API de base de TensorFlow, mais elle continue d'être développée comme un logiciel indépendant. Keras est conçu pour être convivial, réduisant les actions des utilisateurs au minimum tout en offrant une grande flexibilité. [84]



FIGURE 5.8 – Logo de keras. [85]

- **Scikit-learn** également connu sous le nom de sklearn, est la bibliothèque Python la plus puissante et la plus robuste pour l'apprentissage automatique. Elle offre une gamme complète d'outils pour les tâches de machine learning, telles que la classification, la régression, le clustering, ainsi que des fonctionnalités telles que l'estimation de forêts aléatoires, de régressions logistiques, d'algorithmes de classification et de machines à vecteurs de support. Cette bibliothèque est principalement écrite en Python et repose sur des bibliothèques telles que NumPy, SciPy, et Matplotlib. Elle est développée par une communauté de contributeurs, y compris des instituts français de recherche tels qu'inria et Télécom ParisTech, et est conçue pour s'intégrer harmonieusement avec d'autres bibliothèques Python open source. []



FIGURE 5.9 – Logo de Scikit-learn. [94]

## 5.3 Métriques d'évaluation des performances

Les métriques d'évaluation sont des mesures quantitatives servant à évaluer la performance d'un modèle statistique ou d'apprentissage automatique. Elles permettent d'obtenir des informations sur la capacité prédictive, la généralisation et la qualité globale d'un modèle. Le choix de ces métriques dépend du domaine du problème, du type de données et du résultat souhaité. Elles sont essentielles pour s'assurer que le modèle offre une haute précision, en particulier sur des données non vues. Dans le domaine de l'apprentissage automatique, de nombreuses métriques sont utilisées en fonction du type de modèle et de l'objectif de mise en œuvre. [95]

Dans ce qui suit, nous allons présenter les métriques d'évaluation pour lesquelles nous avons opté pour nos modèles :

### 5.3.1 Matrice de confusion

Une matrice de confusion est un tableau de dimensions  $N \times N$ , où  $N$  représente le nombre de catégories prédites. Dans ce cas précis, qui concerne la classification des mélanomes, il y a deux catégories possibles : les mélanomes (cancéreux) et les non-mélanomes (non-cancéreux). Par conséquent,  $N=2$ , ce qui équivaut à une matrice de  $2 \times 2$ . Cette matrice sert d'outil pour évaluer la performance dans les problèmes de classification en apprentissage automatique, lorsqu'il y a deux classes ou plus en sortie. Elle répertorie les quatre combinaisons possibles entre les valeurs prédites par le modèle et les valeurs réelles, ce qui en fait un outil extrêmement utile pour calculer des métriques telles que la précision, le rappel, la spécificité, et surtout pour créer des courbes AUC-ROC. [95]

Confusion matrix		Reality	
		Negative : 0	Positive : 1
Prediction	Negative : 0	True Negative : TN	False Negative : FN
	Positive : 1	False Positive : FP	True Positive : TP

FIGURE 5.10 – Matrice de confusion. [96]

La matrice de confusion est constituée de quatre valeurs :

- **Vrais positifs (True Positives - TP)** : Il s'agit du nombre d'images correctement classifiées comme des patients atteints de mélanome. En d'autres termes, ces images sont effectivement de patients atteints de mélanome, et le modèle les a identifiées comme telles de manière correcte.
- **Faux négatifs (False Negatives - FN)** : Le FN représente le nombre d'images qui ont été incorrectement classifiées comme des patients non atteints de mélanome alors qu'en réalité, ils en sont atteints. Ces images représentent des cas où le modèle a manqué la détection du mélanome.
- **Vrais négatifs (True Negatives - TN)** : Les TN sont le nombre d'images correctement classifiées comme des patients non atteints de mélanome. En d'autres termes, ces images ne montrent pas de mélanome, et le modèle les a correctement identifiées comme telles.
- **Faux positifs (False Positives - FP)** : C'est le nombre d'images qui ont été incorrectement classifiées comme des patients atteints de mélanome. Ces images ne sont pas de patients atteints de mélanome, mais le modèle les a malheureusement identifiées comme telles.

### 5.3.2 Accuracy

La métrique de base utilisée pour l'évaluation des modèles est souvent la Précision, qui décrit le nombre de prédictions correctes par rapport à l'ensemble de toutes les prédictions. [97] Sa représentation mathématique est donnée par la formule suivante :

$$accuracy = \frac{true\ positives + true\ negatives}{true\ positives + true\ negatives + false\ negatives + false\ positives}$$

### 5.3.3 La précision

La précision est une métrique qui calcule la proportion des vrais positifs par rapport au nombre total de positifs prédits par le modèle. [97] Sa représentation mathématique est donnée par la formule suivante :

$$precision = \frac{true\ positives}{true\ positives + false\ positives}$$

### 5.3.4 Recall

La sensibilité est une mesure du nombre de cas positifs que le classificateur a correctement prédits, par rapport à tous les cas positifs dans les données. [97] Sa représentation mathématique est donnée par la formule suivante :

$$\text{recall} = \frac{\text{true positives}}{\text{true positives} + \text{false negatives}}$$

### 5.3.5 F1-score

Le F1-Score est une mesure combinant à la fois la précision et le rappel. [97] Il est généralement décrit comme la moyenne harmonique des deux. [97] Sa représentation mathématique est donnée par la formule suivante :

$$F1 = 2 \cdot \frac{\text{precision} \cdot \text{recall}}{\text{precision} + \text{recall}}$$

### 5.3.6 Aire sous la Courbe ROC (AUC-ROC) :

La courbe ROC-AUC est un indicateur clé en apprentissage automatique pour évaluer la performance des modèles de classification binaire. La courbe ROC illustre le taux de vrais positifs (TPR) en fonction du taux de faux positifs (FPR) à différents seuils, offrant une représentation graphique de la capacité d'un modèle à discriminer entre les classes à différents niveaux de seuil. L'AUC, ou "Zone sous la courbe", quantifie la performance globale du modèle en mesurant l'ensemble de la zone sous la courbe ROC. Une valeur d'AUC proche de 1 signifie que le modèle a une excellente capacité de discrimination entre les classes. Il est crucial de noter qu'une valeur d'AUC de 0.5 indique que le modèle effectue une classification purement aléatoire, sans aucune capacité discriminative. En résumé, la métrique ROC-AUC est essentielle pour évaluer et optimiser la capacité d'un modèle à classer correctement les données. [98]

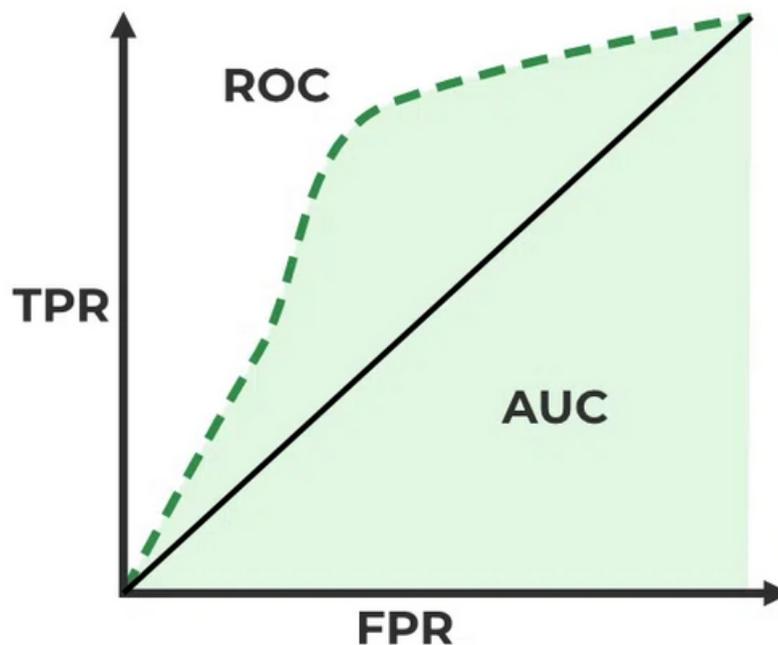


FIGURE 5.11 – Courbe ROC-AUC. [98]

## 5.4 Importation des modèles pré-entraînés

Les codes présentés ci-dessous détaillent la méthode pour importer et utiliser plusieurs modèles renommés de Keras, tous pré-entraînés sur le jeu de données ImageNet. En sélectionnant 'include\_top=False', nous écartons la couche finale de classification de ces architectures, permettant ainsi leur utilisation comme d'efficaces extracteurs de caractéristiques. Par ailleurs, en configurant chaque couche à l'état non entraînable, nous assurons la conservation des poids pré-entraînés. Cette stratégie offre une transition fluide pour intégrer ces architectures dans de nouvelles applications, bénéficiant ainsi des connaissances préalablement acquises sur ImageNet.

```
[30]:
from keras.applications import DenseNet201
pre_trained_model = DenseNet201(include_top = False, weights = 'imagenet')

for layer in pre_trained_model.layers:
    layer.trainable = False

Downloading data from https://storage.googleapis.com/tensorflow/keras-applications/densenet/densenet201_weights_tf_dim_ordering_tf_kernels_notop.h5
74836368/74836368 [=====] - 0s 0us/step
```

FIGURE 5.12 – Importation du modèle DenseNet-201.

```
[51]:
from keras.applications import ResNet50V2
pre_trained_model = ResNet50V2(include_top = False, weights = 'imagenet')

for layer in pre_trained_model.layers:
    layer.trainable = False

Downloading data from https://storage.googleapis.com/tensorflow/keras-applications/resnet/resnet50v2_weights_tf_dim_ordering_tf_kernels_notop.h5
94668760/94668760 [=====] - 0s 0us/step
```

FIGURE 5.13 – Importation du modèle ResNet-50.

```
[76]:
from keras.applications import InceptionResNetV2
pre_trained_model = InceptionResNetV2(include_top = False, weights = 'imagenet')

for layer in pre_trained_model.layers:
    layer.trainable = False

Downloading data from https://storage.googleapis.com/tensorflow/keras-applications/inception_resnet_v2/inception_resnet_v2_weights_tf_dim_ordering_tf_kernels_notop.h5
219055592/219055592 [=====] - 1s 0us/step
```

FIGURE 5.14 – Importation du modèle InceptionResNetV2.

```
[98]:
from keras.applications import Xception

pre_trained_model = Xception(include_top=False, weights='imagenet')

for layer in pre_trained_model.layers:
    layer.trainable = False

Downloading data from https://storage.googleapis.com/tensorflow/keras-applications/xception/xception_weights_tf_dim_ordering_tf_kernels_notop.h5
83683744/83683744 [=====] - 0s 0us/step
```

FIGURE 5.15 – Importation du modèle Xception.

```
[120]: from keras.applications.mobilenet_v2 import MobileNetV2
pre_trained_model = MobileNetV2(include_top=False, weights='imagenet')

for layer in pre_trained_model.layers:
    layer.trainable = False

Downloading data from https://storage.googleapis.com/tensorflow/keras-applications/mobilenet_v2/mobilenet_v2_weights_tf_dim_ordering_tf_kernels_1.0_224_no_top.h5
9406464/9406464 [=====] - 0s 0us/step
```

FIGURE 5.16 – Importation du modèle MobileNet.

## 5.5 Compilation des modèles

Le code présenté propose une méthode pour tirer parti de ces modèles dans le contexte de la classification du mélanome, une tâche binaire cruciale pour la détection précoce du cancer de la peau.

La fonction `custom_model` décrit le processus de construction du réseau. Suite à l'augmentation des données (`data_augmentation`) et au redimensionnement (`rescale`), les images sont acheminées à travers le modèle pré-entraîné pour extraire des caractéristiques pertinentes. Pour capter des représentations plus complexes, une couche dense de 512 neurones avec une activation ReLU est ajoutée. Pour combattre le surapprentissage et assurer une bonne généralisation, une couche Dropout avec un taux de 0,5 est incorporée.

Le choix de la fonction d'activation sigmoïde pour la dernière couche et de la fonction de perte `binary_crossentropy` n'est pas arbitraire. En effet, la classification du mélanome étant un problème binaire (mélanome vs non-mélanome), la fonction sigmoïde est idéale car elle renvoie une valeur unique entre 0 et 1, correspondant à la probabilité qu'une image soit classée comme mélanome. La `binary_crossentropy` est ensuite utilisée comme fonction de perte car elle est spécifiquement conçue pour mesurer l'erreur dans les tâches de classification binaire. Lors de la compilation du modèle, l'optimiseur Adam est choisi pour sa capacité reconnue à converger rapidement et efficacement dans de nombreuses tâches d'apprentissage profond.

Ensemble, ces choix assurent que le modèle est optimisé pour distinguer avec précision les cas de mélanome des cas non-mélanomes.

Pour concrétiser l'architecture, la fonction est invoquée en fournissant un modèle pré-entraîné, un taux d'apprentissage de 0,0001, et une forme d'entrée de (224, 224, 3).

```
[32]:
from tensorflow.keras import layers, Model, Input
import tensorflow as tf

def custom_model(pre_trained_model, lr, input_shape):
    inputs = Input(shape=input_shape)
    x = data_augmentation(inputs)
    x = rescale(x)
    x = pre_trained_model(x)
    x = layers.Flatten()(x)
    x = layers.Dense(512, activation='relu')(x)
    x = layers.Dropout(0.5)(x)
    x = layers.Dense(1, activation='sigmoid')(x)
    model = Model(inputs=inputs, outputs=x)

    model.compile(optimizer=tf.keras.optimizers.Adam(learning_rate=lr),
                  loss='binary_crossentropy',
                  metrics=['accuracy'])

    return model

[33]:
model = custom_model(pre_trained_model, 0.0001, (224,224,3))
```

FIGURE 5.17 – Modification d'Architecture pour les Modèles Pré-entraînés

## 5.6 Optimisation et Sauvegarde du Modèle à l'Aide de Callbacks

En entraînant des modèles de deep learning, il est crucial d'assurer une convergence efficace et de prévenir le surapprentissage, tout en sauvegardant les meilleurs poids du modèle. Le code fourni illustre l'utilisation de "callbacks" dans TensorFlow pour gérer ces préoccupations lors de l'entraînement d'un modèle pour la classification binaire du mélanome.

1. **Réduction du Taux d'Apprentissage sur Plateau (ReduceLRonPlateau)** : Lors de l'entraînement de réseaux neuronaux, il peut arriver que le modèle atteigne un plateau où il ne parvient plus à améliorer la fonction de perte. Pour surmonter ces plateaux et aider le modèle à converger vers un minimum global, on peut réduire le taux d'apprentissage. Dans ce callback, le taux d'apprentissage est réduit par un facteur de 0,1 si la "val\_loss" (perte de validation) ne s'améliore pas pendant 3 époques consécutives. Le taux d'apprentissage ne sera pas réduit en dessous de 109109, assurant ainsi qu'il ne devienne pas insignifiant.
2. **Enregistrement du Meilleur Modèle (ModelCheckpoint)** : Lors de l'entraînement, il est essentiel de sauvegarder les poids du modèle qui offrent les meilleures performances sur l'ensemble de validation. Le callback ModelCheckpoint est utilisé pour sauvegarder les poids du modèle dans le fichier 'model\_weight.h5' chaque fois qu'il y a une amélioration du modèle (basée sur la perte de validation). L'option save\_best\_only=True garantit que seuls les meilleurs poids sont sauvegardés, évitant ainsi l'encombrement du disque avec des versions inutiles du modèle. De plus, avec verbose=2, ce callback affichera des messages détaillés à chaque fois qu'il sauvegarde le modèle, fournissant ainsi un retour d'information en temps réel sur le processus de sauvegarde.
3. **Arrêt Précoce (EarlyStopping)** : Pour éviter un entraînement inutilement long et prévenir le surapprentissage, le callback EarlyStopping interrompt l'entraînement si la

perte de validation ne s'améliore pas pendant 10 époques consécutives. Cela garantit que le modèle ne continuera pas à s'entraîner une fois qu'il a cessé de faire des progrès significatifs.

Ces callbacks, ensemble, offrent une stratégie robuste pour entraîner efficacement un modèle tout en garantissant qu'il ne surapprend pas et en conservant les meilleures versions du modèle pour une éventuelle utilisation ou évaluation ultérieure.

```
[31]: my_callbacks = [
      tf.keras.callbacks.ReduceLROnPlateau(monitor="val_loss", factor=0.1, patience=3, min_lr=0.00000001),
      tf.keras.callbacks.ModelCheckpoint(filepath='model_weight.h5', save_best_only=True, verbose=2),
      tf.keras.callbacks.EarlyStopping(patience=10),
      ]
```

FIGURE 5.18 – Liste des rappels utilisés.

## 5.7 Entraînement du Modèle

Après avoir configuré le modèle et défini une série de "callbacks" pour optimiser le processus d'entraînement, la phase réelle d'entraînement commence, où le modèle apprend des caractéristiques des données fournies.

1. Taille du lot (`batch_size`) : La taille du lot est définie à 16. Cela signifie que, lors de chaque mise à jour des poids du modèle pendant l'entraînement, 16 échantillons sont utilisés pour estimer le gradient de la fonction de perte. Une taille de lot plus petite peut offrir une convergence plus rapide et un apprentissage plus stable, bien qu'elle puisse nécessiter davantage d'itérations.
2. Fit du Modèle : La méthode `fit` est l'endroit où l'entraînement effectif du modèle se produit. Voici une explication détaillée des arguments utilisés :
  - **`train_ds`** : Il s'agit de l'ensemble de données d'entraînement, qui contient les images et leurs étiquettes associées. C'est sur cet ensemble que le modèle apprendra.
  - **`validation_data=valid_ds`** : Il s'agit de l'ensemble de données de validation sur lequel le modèle est évalué après chaque époque. Cela aide à surveiller la performance du modèle sur des données qu'il n'a pas vues pendant l'entraînement, offrant ainsi une indication de sa capacité à généraliser.
  - **`epochs=50`** : Le modèle sera entraîné pendant 50 époques. Une époque signifie que chaque échantillon de l'ensemble de données d'entraînement a été utilisé une fois pour mettre à jour les poids du modèle.
  - **`batch_size=batch_size`** : Cet argument précise que la taille du lot pour l'entraînement est celle définie précédemment (16 dans ce cas).
  - **`verbose=1`** : Cela détermine le type d'affichage pendant l'entraînement. Avec `verbose=1`, des barres de progression et des messages d'information seront affichés pour chaque époque.
  - **`callbacks=my_callbacks`** : Les callbacks définis précédemment sont utilisés pendant l'entraînement. Ces callbacks peuvent interrompre l'entraînement, ajuster le taux d'apprentissage ou sauvegarder les poids du modèle selon les conditions spécifiées.

À l'issue de l'entraînement, les résultats, tels que la perte d'entraînement, la précision d'entraînement, la perte de validation et la précision de validation pour chaque époque, sont stockés dans l'objet `history`. Cela permet une analyse postérieure, par exemple, pour visualiser la convergence du modèle ou détecter le surapprentissage.

```
[34]: batch_size = 16

history = model.fit(train_ds,
                    validation_data=valid_ds,
                    epochs=50,
                    batch_size=batch_size,
                    verbose=1,
                    callbacks=my_callbacks)
```

FIGURE 5.19 – Phase d'entraînement du modèle.

## 5.8 Analyse de la Convergence du Modèle

L'évaluation d'un modèle de deep learning s'appuie souvent sur deux indicateurs clés : la précision (accuracy) et la perte (loss). Lors de la phase d'entraînement, il est primordial de surveiller l'évolution de ces indicateurs, non seulement sur l'ensemble d'entraînement, mais aussi sur l'ensemble de validation. L'analyse des courbes de précision et de perte en entraînement et en validation permet de cerner le comportement du modèle : surapprentissage (overfitting), sous-apprentissage (underfitting) ou un équilibre optimal.

Dans cette section, nous explorerons et comparerons les courbes de précision et de perte des cinq modèles que nous avons sélectionnés, tous basés sur le transfer learning.

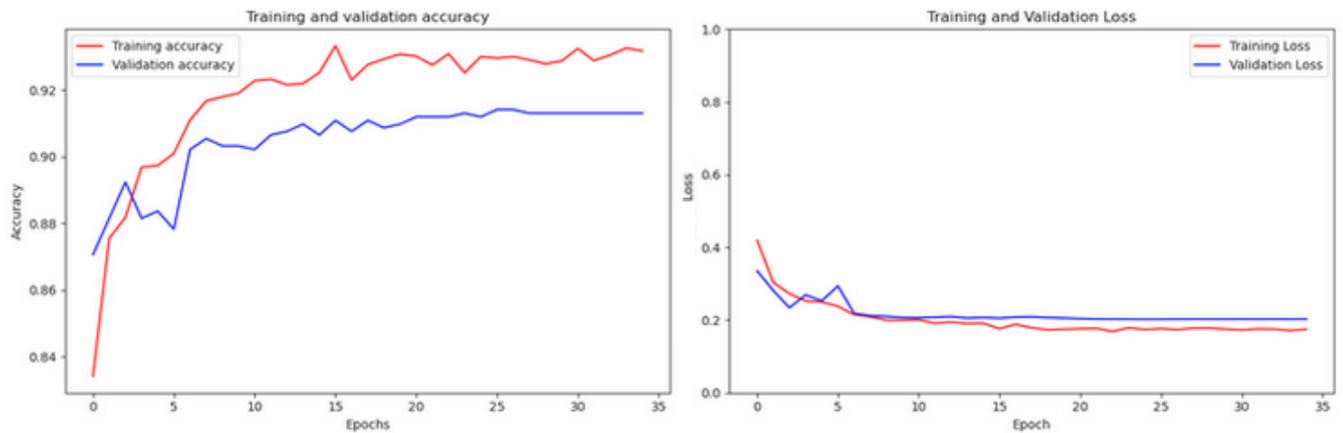


FIGURE 5.20 – Évolution de l'accuracy et de la Loss durant l'entraînement et la validation pour DenseNet201

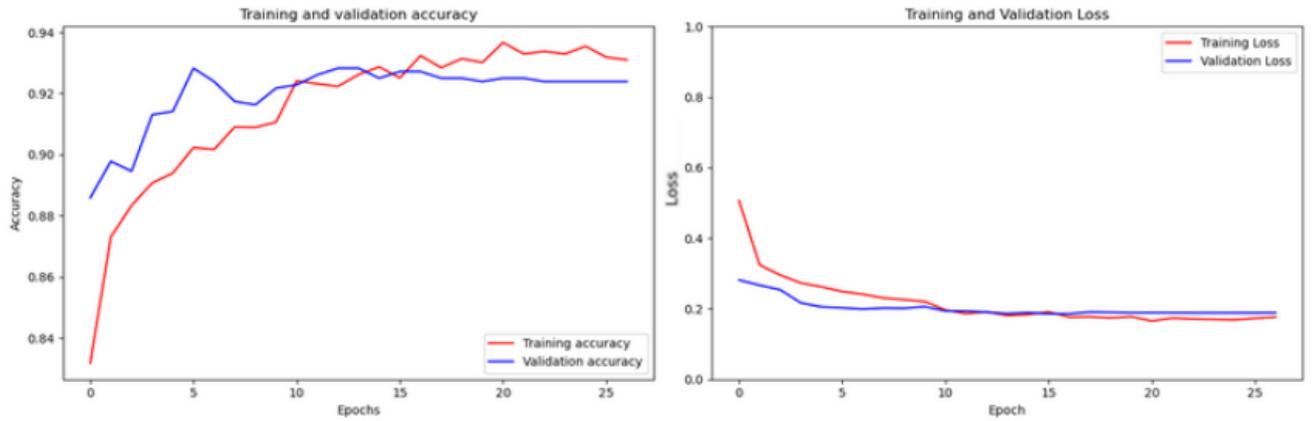


FIGURE 5.21 – Évolution de l’accuracy et de la Loss durant l’entraînement et la validation pour ResNet50.

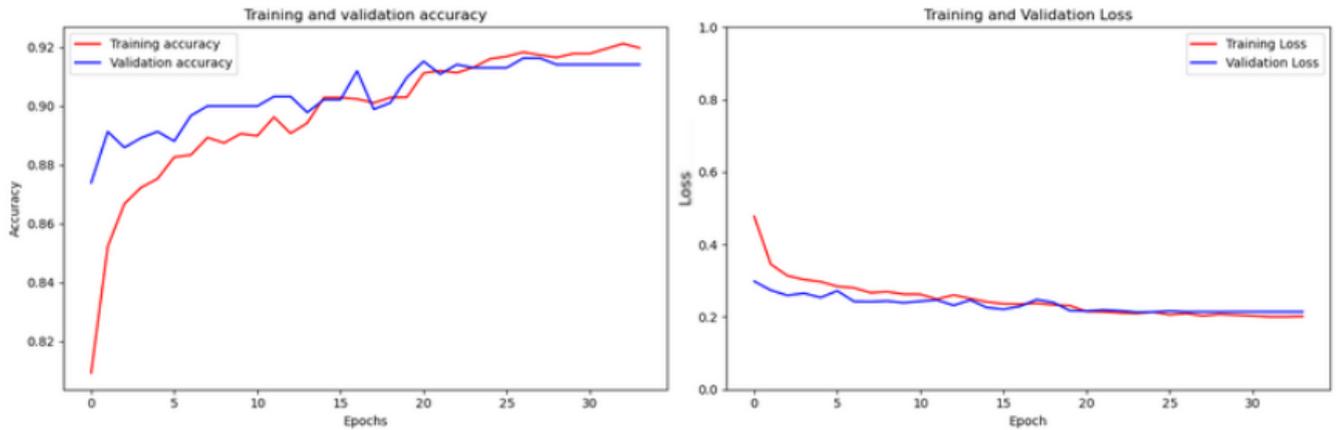


FIGURE 5.22 – Évolution de l’accuracy et de la Loss durant l’entraînement et la validation pour InceptionResNet.

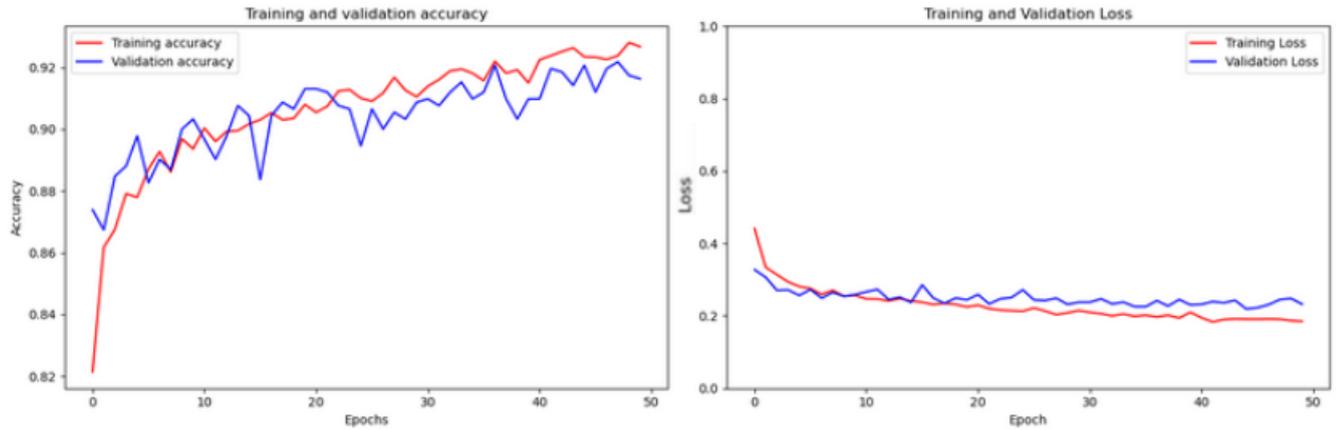


FIGURE 5.23 – Évolution de l’accuracy et de la Loss durant l’entraînement et la validation pour Xception.

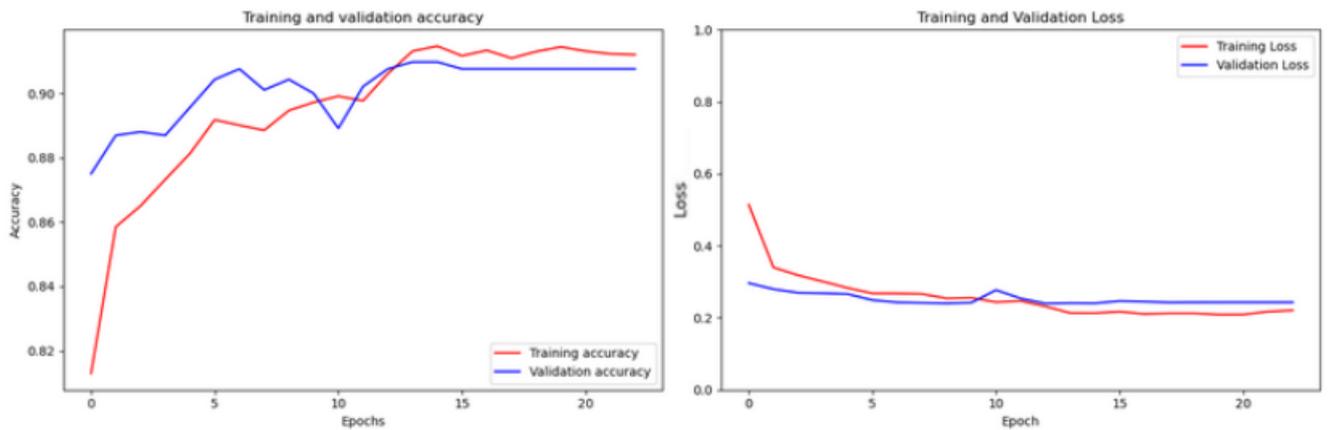


FIGURE 5.24 – Évolution de l’accuracy et de la Loss durant l’entraînement et la validation pour MobileNet.

### 5.8.1 Discussion

Suite à une analyse visuelle approfondie des graphes représentant les performances de nos cinq modèles, il est clair qu’il n’y a pas de signes d’overfitting ni d’underfitting. Les modèles semblent bien se comporter tant sur les données d’entraînement que sur les données de validation, indiquant une bonne généralisation. De plus, il est important de souligner que les modèles ont convergé de manière remarquablement rapide et efficace lors de l’entraînement.

Ce succès dans la convergence des modèles est en grande partie attribuable aux paramètres que nous avons judicieusement choisis pour l’ensemble de l’entraînement. Nous avons sélectionné des hyperparamètres adaptés à notre problème, ce qui a grandement contribué à

l'efficacité de nos modèles.

En particulier, nous avons mis en avant l'utilisation d'un callback personnalisé, soigneusement configuré pour surveiller les performances de nos cinq modèles tout au long de l'entraînement. Les ajustements que nous avons apportés ont porté leurs fruits, car ils ont permis aux cinq modèles de converger de manière stable et rapide. Au bout de seulement 10 epochs, l'entraînement s'est arrêté automatiquement sur l'ensemble des modèles une fois que les performances ont commencé à se stabiliser sans montrer d'améliorations significatives. Cette approche a permis d'économiser du temps et des ressources tout en garantissant que nos cinq modèles atteignent des performances optimales.

Dans la suite, nous allons effectuer une comparaison en détail de ces cinq modèles en utilisant diverses métriques pour valider et affiner nos résultats.

## 5.9 Analyse Comparative des Modèles

Après avoir examiné en détail la performance et la convergence de nos cinq modèles, nous sommes désormais prêts à approfondir notre évaluation dans cette section consacrée à la comparaison. Notre précédente investigation a déjà mis en lumière des indications positives quant à la capacité de nos modèles à généraliser efficacement. Notre objectif ici est d'entreprendre une analyse comparative approfondie, en utilisant une variété de métriques et d'évaluation. Cette analyse comparative nous permettra de mieux comprendre les avantages et les inconvénients de chaque modèle, de mettre en évidence leurs performances relatives et de prendre des décisions éclairées pour notre application spécifique. Décortiquons donc cette exploration approfondie de nos cinq modèles pour révéler les détails les plus pertinents pour notre projet.

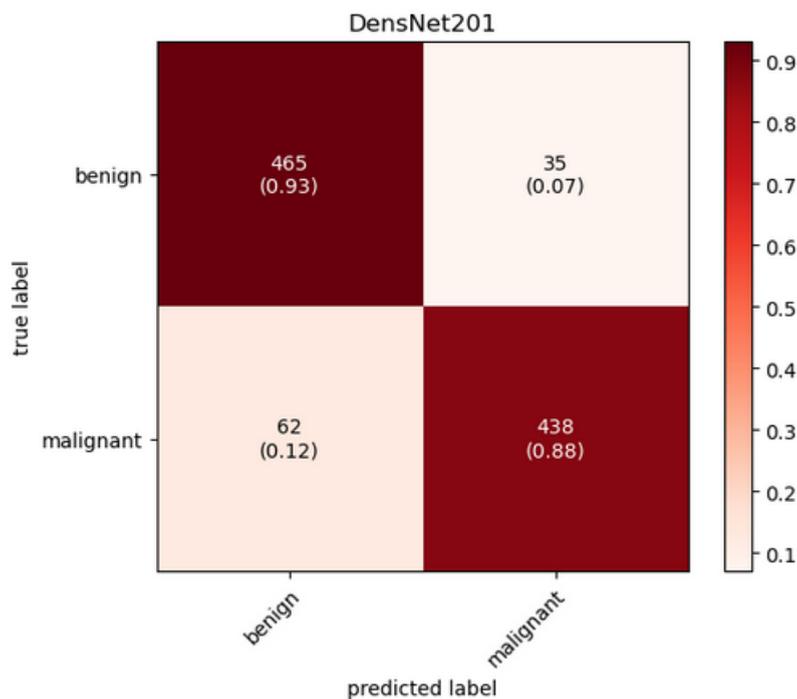


FIGURE 5.25 – Matrice de confusion du modèle DenseNet201.

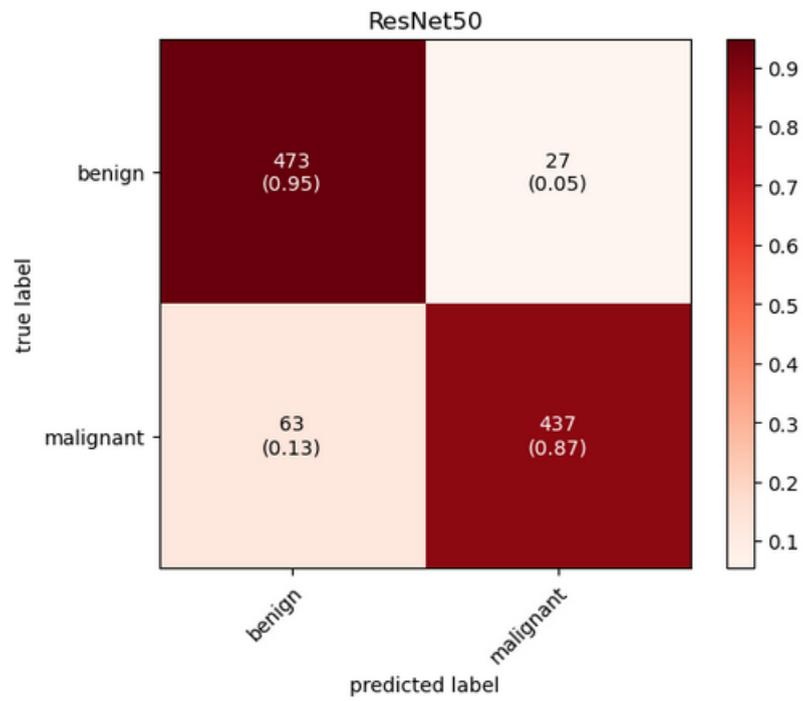


FIGURE 5.26 – Matrice de confusion du modèle ResNet50.

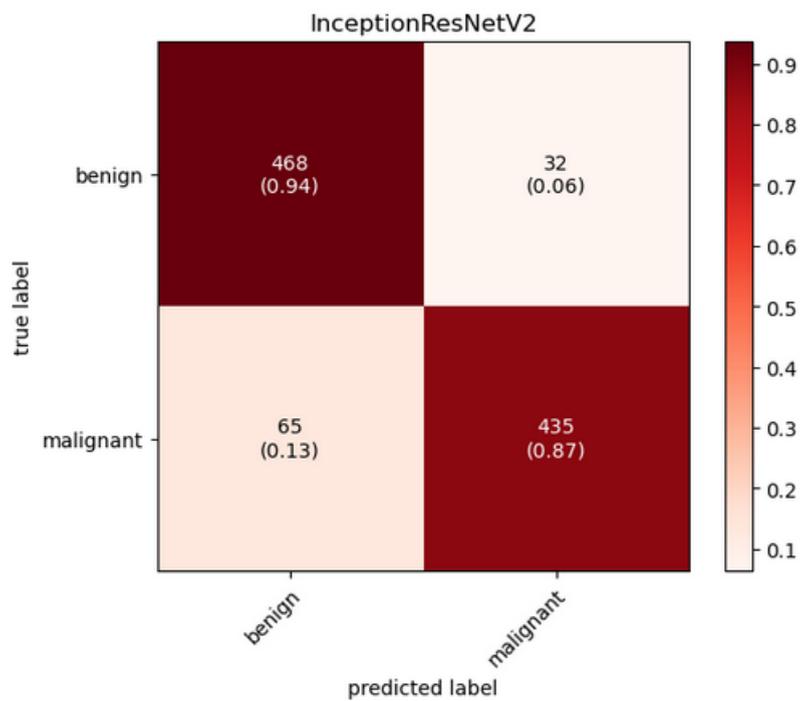


FIGURE 5.27 – Matrice de confusion du modèle InceptionResNet.

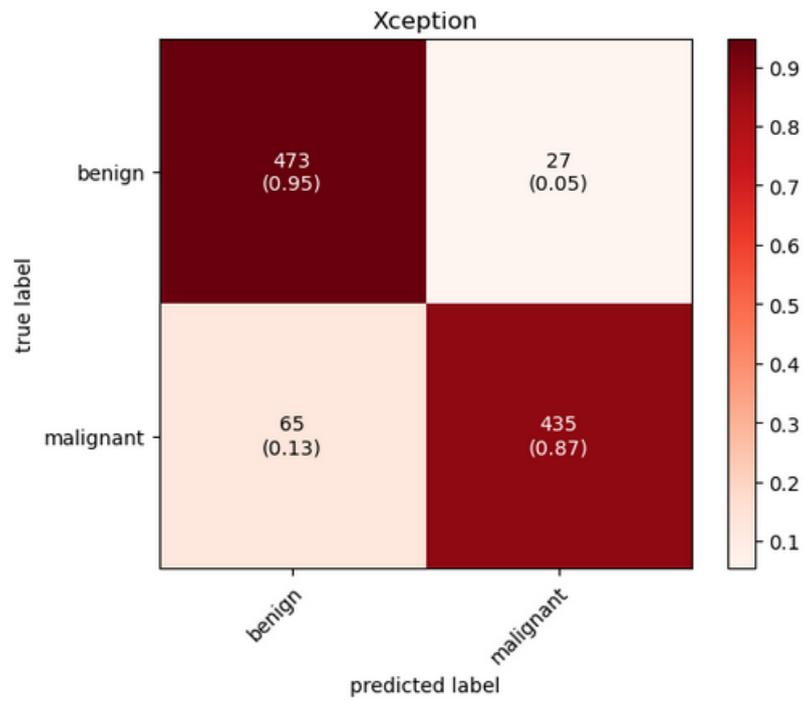


FIGURE 5.28 – Matrice de confusion du modèle Xception.

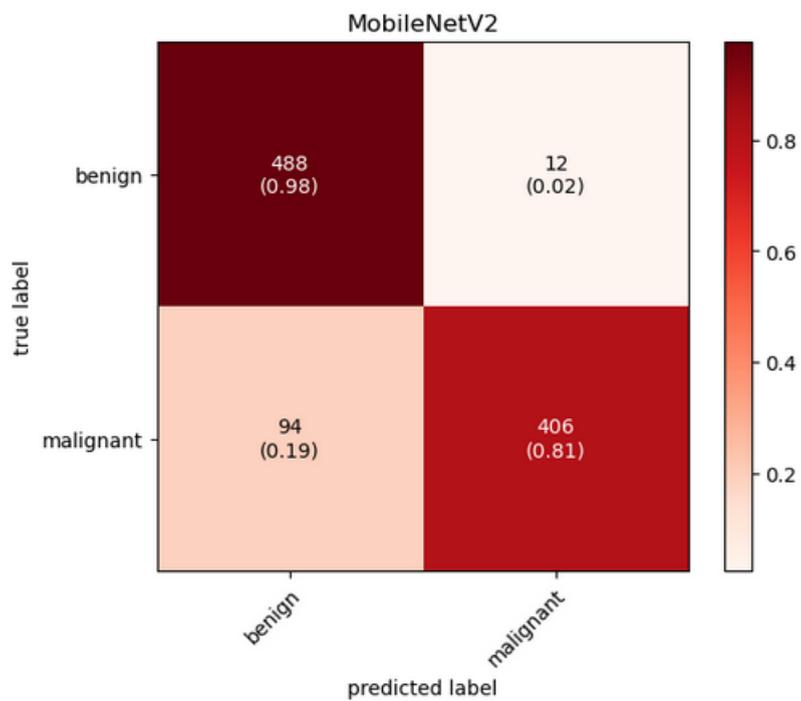


FIGURE 5.29 – Matrice de confusion du modèle MobileNet.

Modèle / Métrique	Accuracy	Precision	Recall	F1-Score	ROC-AUC
DenseNet201	0.903	0.926	0.876	0.900	0.903
ResNet50	0.91	0.941	0.874	0.906	0.910
Inception ResNet	0.903	0.931	0.87	0.899	0.903
Xception	0.908	0.941	0.87	0.904	0.908
MobileNet	0.894	0.971	0.812	0.884	0.894

TABLE 5.1 – Tableau comparatif entre nos différents modèles.

### 5.9.1 Discussion

- **Recall** : DenseNet201 présente le meilleur rappel avec une valeur de 0,876, suivi de près par ResNet50 et InceptionResNetV2 avec des valeurs de 0,874 et 0,87 respectivement. En revanche, MobileNet affiche le rappel le plus bas à 0,812, ce qui suggère qu’il pourrait manquer davantage de vrais positifs par rapport aux autres modèles.
- **Précision** : La précision indique combien des prédictions positives du modèle sont réellement correctes. MobileNet excelle dans cette métrique avec une impressionnante précision de 97.13%. Cependant, cela, combiné à son faible rappel, suggère que bien qu’il prédit moins fréquemment des positifs, quand il le fait, il est très confiant et souvent correct. ResNet50 et Xception suivent avec des précisions respectives de 94.18% et 94.16%.
- **Accuracy** : ResNet50 mène le peloton avec une exactitude de 91%, tandis que DenseNet201, InceptionResNetV2, et Xception sont tous à égalité à 90.3% ou 90.8%. MobileNet, malgré sa haute précision, à l’exactitude la plus basse à 89.4%.
- **Score F1** : Encore une fois, ResNet50 se démarque avec le score F1 le plus élevé à 90.66%. Les autres modèles, à l’exception de MobileNet, ont des scores F1 très similaires, variant de 89.97% à 90.44%.
- **AUC ROC** : ResNet50 et Xception partagent la première place avec un AUC ROC de 91% et 90.8% respectivement. Les autres modèles sont soit à 90.3% ou à 89.4% pour MobileNet.

Pour conclure, si l’on considère toutes les métriques, ResNet50 semble être le modèle le plus équilibré avec les performances les plus élevées dans presque toutes les métriques. Cependant, si la précision est la métrique la plus importante, MobileNet est le meilleur, bien qu’il sacrifie le rappel pour atteindre cette précision. D’autre part, DenseNet201, InceptionResNetV2, et Xception offrent des performances très compétitives et sont très similaires dans leurs métriques, faisant de chacun d’eux un choix potentiellement bon selon les spécificités du cas d’utilisation.

### 5.9.2 Comparaison avec d’Autres Approches

Dans le cadre de notre étude comparative, après avoir examiné en détail nos différents modèles entre eux, nous allons maintenant les confronter à d’autres approches existantes. La table ci-dessus, élaborée en référence à l’article [104], servira de base à cette analyse comparative.

Study	Algorithm	Dataset	Recall	Specificity	Accuracy
Codella et al.,2017	CNN model	ISIC 2016	54	93	85
Lopez et al.,2017	CNN model + transfer learning	ISIC 2016	78	-	81
Yu et al.,2017	FCRN + DRN	ISIC 2016	51	94	85
Quang,2017	ConvNet	ISIC 2017	83	41	49
	VGG16 + transfer learning		34	90	79
Ayan et al.,2018	CNN model with non augmented dataset	ISIC 2016	-	-	78
	CNN model with augmented dataset		-	-	81
Notre approche	DenseNet-201	Melanoma Skin Cancer Dataset of 10000 Images [103]	0.876	0.93	0.903
	ResNet-50		0.874	0.946	0.91
	InceptionResNet		0.870	0.936	0.903
	Xception		0.870	0.946	0.908
	MobileNet		0.812	0.976	0.894

TABLE 5.2 – Tableau comparatif entre différentes approches.

## 5.10 Construction d'un système de classification

Dans le cadre décrit, un mécanisme de vote majoritaire est employé pour améliorer la précision de la classification. Plutôt que de s'appuyer sur la prédiction d'un seul modèle, le système utilise plusieurs modèles pré-entraînés. Il est important de noter que le nombre de modèles utilisés doit être impair. Chacun de ces modèles émet un vote (c'est-à-dire une prédiction) concernant la nature d'une image, qu'elle soit bénigne ou maligne. La décision finale est ensuite prise en se basant sur la majorité des votes des différents modèles.

L'utilisation d'un vote majoritaire offre plusieurs avantages. Premièrement, elle permet de tirer parti de la diversité des modèles : si un modèle se trompe en raison de ses particularités ou de ses faiblesses, les autres peuvent corriger cette erreur. Deuxièmement, elle renforce la confiance en une prédiction, car une décision basée sur la convergence de plusieurs modèles est souvent plus fiable que celle basée sur un seul.

En conclusion, en combinant les forces de plusieurs architectures d'apprentissage en pro-

fondeur grâce au vote majoritaire (avec un nombre impair de modèles), nous construisons un système robuste et précis pour la classification du mélanome, augmentant ainsi les chances de détection précoce et de traitement réussi. Pour illustrer l'efficacité de cette approche, la figure suivante présente un exemple concret de vote majoritaire en action.

```

print(f"MobileNet: {mobilenet_pred}")
print(f"DenseNet201: {dense_pred}")
print(f"Inception: {incep_pred}")
print(f"ResNet50V2: {resnet_pred}")
print(f"Xception: {xcep_pred}")

print("\n" + "="*50 + "\n") # Ligne de séparation
print(f"Combinaison de tout les modeles: {com_pred}")

```

```

1/1 [=====] - 0s 25ms/step
1/1 [=====] - 0s 40ms/step
1/1 [=====] - 0s 40ms/step
1/1 [=====] - 0s 24ms/step
1/1 [=====] - 0s 24ms/step

```



Original Class: Malignant

```

MobileNet: Benign
DenseNet201: Malignant
Inception: Benign
ResNet50V2: Malignant
Xception: Malignant

=====

Combinaison de tout les modeles: Malignant

```

FIGURE 5.30 – Illustration de l'utilisation du vote majoritaire.

## 5.11 Conclusion

Dans ce chapitre, nous avons décrit notre stratégie pour développer un système efficace de classification du mélanome. Nous avons d'abord mis en avant cinq modèles issus du transfer learning. Dans un premier temps, ces modèles ont agi indépendamment, chacun apportant sa propre expertise et spécificité à la tâche. Ensuite, ces modèles ont été combinés grâce à une technique d'ensemble learning, fusionnant ainsi leurs forces pour optimiser la précision de la classification.

Cette démarche, qui commence par une action individuelle des modèles de transfer learning puis aboutit à leur union via l'ensemble learning, souligne la sophistication et l'efficacité de notre approche dans le domaine du deep learning. Suite à cette intégration, la précision de notre classification s'est renforcée à chaque itération.

Dans le chapitre suivant, nous dresserons une synthèse de nos travaux et mettrons en avant nos principales découvertes.

## *Conclusion générale*

En conclusion, notre étude met en lumière l'importance cruciale de la détection précoce et de la classification précise du mélanome, un cancer de la peau potentiellement mortel. Dans un contexte où l'informatique médicale et l'intelligence artificielle progressent rapidement, nous avons développé une approche appelée "Transfer Learning with Ensembles of Deep Neural Networks for Skin Cancer".

Notre méthode repose sur l'utilisation de cinq modèles de transfert de pointe, à savoir DenseNet121, ResNet50, InceptionResNet, Xception et MobileNet, qui ont atteint des exactitudes respectives de 0,903, 0,910, 0,903, 0,908 et 0,894. Pour accroître la précision de la classification, nous avons mis en place un système de classification par vote majoritaire, garantissant une classification robuste et fiable. Cependant, l'approche par vote majoritaire, bien qu'efficace, a ses propres limites et il serait bénéfique d'explorer d'autres méthodes d'ensemble pour améliorer davantage la robustesse.

Lors de la préparation des données, nous avons utilisé l'oversampling pour équilibrer les classes, ce qui peut potentiellement introduire une perte d'information originale. De futures améliorations devraient explorer des méthodes d'équilibrage plus sophistiquées. De plus, nous n'avons pas effectué une vérification approfondie du jeu de données pour détecter des images en double ou supprimer des artefacts, ce qui peut affecter la performance du modèle.

Nos résultats préliminaires sont extrêmement prometteurs, avec une exactitude impressionnante dans la classification du mélanome. À l'avenir, nous prévoyons de finaliser l'implémentation de notre modèle et d'effectuer davantage de tests pour consolider ces résultats encourageants. De plus, nous envisageons d'enrichir notre modèle pour qu'il puisse également prédire l'évolution et la gravité du mélanome chez un individu, ouvrant ainsi de nouvelles perspectives pour la prévention et le traitement de cette maladie redoutable.

# Bibliographie

1. « Benign and malignant melanoma | Download Scientific Diagram ». [https://www.researchgate.net/figure/Benign-and-malignant-melanoma\\_fig1\\_338474285](https://www.researchgate.net/figure/Benign-and-malignant-melanoma_fig1_338474285) (consulté le 6 août 2023).
2. « DermoExpert: Skin lesion classification using a hybrid convolutional neural network through segmentation, transfer learning, and augmentation - ScienceDirect ». <https://www.sciencedirect.com/science/article/pii/S2352914821002835?via%3Dihub> (consulté le 8 août 2023).
3. A. C. F. Gouabou, F. Heim, et J.-L. Damoiseaux, « Apprentissage profond pour l'aide au diagnostic du mélanome à partir d'exemple », report, Université de Haute-Alsace, 2019 <https://amu.hal.science/hal-02515203> (consulté le 8 août 2023)
4. *Melanoma: Facts & Stats About Skin Cancer*. (n.d.). Melanoma Research Alliance. <https://www.curemelanoma.org/about-melanoma/melanoma-101/melanoma-statistics-2> (consulté le 8 août 2023)
5. D. Emerson, « Malignant Melanoma-Stage Dictates Prognosis », *PeopleBeatingCancer*, 4 mai 2022. <https://peoplebeatingcancer.org/malignant-melanoma-stage-dictates-prognosis/> (consulté le 8 août 2023).
6. Dermato-Info, « la méthode ABCDE », *dermato-info.fr*, 3 décembre 2019. [https://dermato-info.fr/fr/les-conseils-dermato\\_tutos-peau/l%E2%80%99auto-examen-de-la-peau\\_la-m%C3%A9thode-ABCDE](https://dermato-info.fr/fr/les-conseils-dermato_tutos-peau/l%E2%80%99auto-examen-de-la-peau_la-m%C3%A9thode-ABCDE) (consulté le 8 août 2023).
7. Doctissimo, « Cancer de la peau : les signes qui doivent alerter », *Doctissimo*, 6 novembre 2022. [https://www.doctissimo.fr/html/sante/principalespatho/sa\\_130\\_peau\\_quad.htm](https://www.doctissimo.fr/html/sante/principalespatho/sa_130_peau_quad.htm) (consulté le 8 août 2023).

8. « Stades de Mélanome – Melanome France ». <http://melanomefrance.com/tous-sur-le-melanome/stades-de-melanome/> (consulté le 9 août 2023).
9. « Stades du mélanome », *The Skin Cancer Foundation*. <https://www.skincancer.org/fr/skin-cancer-information/melanoma/the-stages-of-melanoma/> (consulté le 9 août 2023).
10. « Stades du mélanome », *Muy Salud*, 16 juin 2023. <https://muysalud.com/fr/maladies/stades-du-melanome/> (consulté le 9 août 2023).
11. « Les symptômes et l'évolution des mélanomes », *VIDAL*. <https://www.vidal.fr/maladies/cancers/melanome-cancer-peau/symptomes-evolution.html> (consulté le 9 août 2023).
12. S. Lee, « Stades du mélanome », *Société canadienne du cancer*. <https://cancer.ca/fr/cancer-information/cancer-types/skin-melanoma/staging> (consulté le 9 août 2023).
13. « Intelligence artificielle et santé · Inserm, La science pour la santé », *Inserm*. <https://www.inserm.fr/dossier/intelligence-artificielle-et-sante/> (consulté le 10 août 2023).
14. « Qu'est-ce que l'intelligence artificielle dans le secteur de la santé ? | IBM ». <https://www.ibm.com/fr-fr/topics/artificial-intelligence-healthcare> (consulté le 10 août 2023).
15. « L'OMS publie le premier rapport mondial sur l'intelligence artificielle (IA) appliquée à la santé et six principes directeurs relatifs à sa conception et à son utilisation ». <https://www.who.int/fr/news/item/28-06-2021-who-issues-first-global-report-on-ai-in-health-and-six-guiding-principles-for-its-design-and-use> (consulté le 10 août 2023).
16. « Qu'est-ce que le machine learning ? » <https://www.oracle.com/fr/artificial-intelligence/machine-learning/what-is-machine-learning/> (consulté le 10 août 2023).
17. « Machine Learning : Définition, fonctionnement, utilisations », *Formation Data Science | DataScientest.com*, 18 novembre 2020. <https://datascientest.com/machine-learning-tout-savoir> (consulté le 10 août 2023).

18. B. L, « Reinforcement Learning : qu'est-ce que l'apprentissage par renforcement ? »  
<https://www.lebigdata.fr/reinforcement-learning-definition> (consulté le 10 août 2023).
19. « Apprentissage par renforcement ».  
<https://www.cnil.fr/fr/definition/apprentissage-par-renforcement> (consulté le 10 août 2023).
20. C. Deluzarche, « Définition | Deep Learning - Apprentissage profond | Futura Tech », *Futura*.  
<https://www.futura-sciences.com/tech/definitions/intelligence-artificielle-deep-learning-17262/> (consulté le 12 août 2023).
21. B. L, « Deep Learning ou apprentissage profond : définition, concept ».  
<https://www.lebigdata.fr/deep-learning-definition> (consulté le 12 août 2023).
22. T. Bigdata.ma, « Qu'est-ce qui différencie le Machine Learning du Deep Learning ? »  
<https://www.bigdata.ma/quest-ce-qui-differencie-le-machine-learning-du-deep-learning/> (consulté le 12 août 2023).
23. D. Ade, « Deep learning vs. machine learning: Understanding the differences », *MEGATEK ICT ACADEMY*, 11 février 2020.  
<https://ictacademy.com.ng/deep-learning-vs-machine-learning-understanding-the-differences/> (consulté le 12 août 2023).
24. « 1-s2.0-S0181551221005842-gr1.jpg (Image JPEG, 546 × 411 pixels) ».  
<https://ars.els-cdn.com/content/image/1-s2.0-S0181551221005842-gr1.jpg> (consulté le 12 août 2023).
25. « Réseaux de neurones », *univ-toulouse*. Disponible sur:  
<https://www.math.univ-toulouse.fr/~besse/Wikistat/pdf/st-m-app-rn.pdf> (consulté le 12 août 2023).
26. « Fig. 2.3-Le perceptron multicouches », *ResearchGate*.  
[https://www.researchgate.net/figure/Le-perceptron-multicouches\\_fig6\\_30517821](https://www.researchgate.net/figure/Le-perceptron-multicouches_fig6_30517821) (consulté le 12 août 2023).
27. L. R, « Focus : Le Réseau de Neurones Artificiels ou Perceptron Multicouche », *Pensée Artificielle*, 11 février 2018.  
<https://penseeartificielle.fr/focus-reseau-neurones-artificiels-perceptron-multicouche/> (consulté le 12 août 2023).

28. « Quels sont les différents algorithmes de Deep Learning ? | Jedha ». <https://www.jedha.co/formation-ia/algorithmes-deep-learning> (consulté le 13 août 2023).
29. « Découvrez les différentes couches d'un CNN », *OpenClassrooms*. <https://openclassrooms.com/fr/courses/4470531-classez-et-segmentez-des-donnees-visuelles/5083336-decouvrez-les-differentes-couches-dun-cnn> (consulté le 15 août 2023).
30. « Figure 3. Schematic illustration of a convolutional operation. The... », *ResearchGate*. [https://www.researchgate.net/figure/Schematic-illustration-of-a-convolutional-operation-The-convolutional-kernel-shifts-over\\_fig2\\_332190148](https://www.researchgate.net/figure/Schematic-illustration-of-a-convolutional-operation-The-convolutional-kernel-shifts-over_fig2_332190148) (consulté le 14 août 2023).
31. K. Rana, « Pooling Layer — Short and Simple », *plainenglish.io/blog/pooling-layer-beginner-to-intermediate-fa0dbdce80eb*, 3 avril 2020. <https://plainenglish.io/blog/pooling-layer-beginner-to-intermediate-fa0dbdce80eb> (consulté le 14 août 2023).
32. « CS 230 - Pense-bête de réseaux de neurones convolutionnels ». <https://stanford.edu/~shervine/fr/teaching/cs-230/pense-bete-reseaux-neurones-convolutionnels#layer> (consulté le 15 août 2023).
33. « Chapitre 3 : Réseau de neurones convolutionnel CNN ». [http://staff.univ-batna2.dz/sites/default/files/merzougui\\_ghalia/files/support\\_de\\_cours\\_-deep\\_learning-chapitre3-cnn.pdf](http://staff.univ-batna2.dz/sites/default/files/merzougui_ghalia/files/support_de_cours_-deep_learning-chapitre3-cnn.pdf) (consulté le 15 août 2023).
34. C. T. Diabang, « Améliorations d'un système intelligent de détection et de comptage de graines de semence de résineux », masters, Université du Québec à Trois-Rivières, Trois-Rivières, 2022. [En ligne]. Disponible sur: <https://depot-e.uqtr.ca/id/eprint/10417/> (consulté le 15 août 2023).
35. « Figure 2. Six different types of deep learning models applied for... », *ResearchGate*. [https://www.researchgate.net/figure/Six-different-types-of-deep-learning-models-applied-for-anomaly-detection\\_fig1\\_348231118](https://www.researchgate.net/figure/Six-different-types-of-deep-learning-models-applied-for-anomaly-detection_fig1_348231118) (consulté le 22 août 2023).
36. « Fonctions d'activation les plus utilisées en apprentissage profond | ». <https://lucidar.me/fr/neural-networks/most-popular-activation-functions-for-deep-learning/#relu-parametrique> (consulté le 22 août 2023).

37. « Chapitre 6.2 - Le réseau de neurones », Note de cours rédigée par Simon Vézina, Collège de Maisonneuve  
[https://physique.cmaisonneuve.qc.ca/svezina/mat/note\\_mat/MAT\\_Chap%206.2.pdf](https://physique.cmaisonneuve.qc.ca/svezina/mat/note_mat/MAT_Chap%206.2.pdf)  
(consulté le 22 août 2023).
38. B. Maurice, « Fonction d'activation », *Deeply Learning*, 26 septembre 2018.  
<https://deeplearning.fr/cours-theoriques-deep-learning/fonction-dactivation/>  
(consulté le 22 août 2023).
39. « Le développement d'un mélanome de la peau - Mélanome de la peau ».  
<https://www.e-cancer.fr/Patients-et-proches/Les-cancers/Melanome-de-la-peau/Developpement#toc-les-principaux-types-de-m-lanomes> (consulté le 23 août 2023).
40. « Mélanome (cancer de la peau) - symptômes, causes, traitements et prévention », VIDAL. <https://www.vidal.fr/maladies/cancers/melanome-cancer-peau.html> (consulté le 23 août 2023).
41. « Mélanome : symptômes, diagnostic et évolution ».  
<https://www.ameli.fr/assure/sante/themes/melanome/symptomes-diagnostic-evolution>  
(consulté le 23 août 2023).
42. N. M. Masse Interféron, « MELANOME MALIN Naevus Mélanome - ppt video online télécharger ».  
<https://slideplayer.fr/slide/3394793/> (consulté le 23 août 2023).
43. « Facteurs de risque - Mélanome de la peau ».  
<https://www.e-cancer.fr/Patients-et-proches/Les-cancers/Melanome-de-la-peau/Facteurs-de-risque> (consulté le 23 août 2023).
44. « Mélanome cutané : la détection précoce est essentielle », *Haute Autorité de Santé*.  
[https://www.has-sante.fr/jcms/pprd\\_2974838/fr/melanome-cutane-la-detection-precoce-est-essentielle](https://www.has-sante.fr/jcms/pprd_2974838/fr/melanome-cutane-la-detection-precoce-est-essentielle) (consulté le 23 août 2023).
45. « Cancer de la peau ».  
<https://www.roche.fr/solutions/aires-therapeutiques/oncologie/cancer-peau> (consulté le 24 août 2023).
46. « Image Classification using Convolutional Neural Network and Vision Transformer | by Abhishek k | Medium ».

<https://abhishek673.medium.com/image-classification-using-convolutional-neural-net-work-and-vision-transformer-29758796e08a> (consulté le 24 août 2023).

47. K. Krzyk, « Coding Deep Learning For Beginners », *Medium*, 4 décembre 2018.  
<https://towardsdatascience.com/coding-deep-learning-for-beginners-types-of-machine-learning-b9e651e1ed9d> (consulté le 25 août 2023).
48. C. Pittman, « L'IA au service du diagnostic médical. », *Medium*, 13 mars 2021.  
<https://chloe-pittman.medium.com/ia-au-service-du-diagnostic-medical-ae35a9ae6fa8> (consulté le 27 août 2023).
49. V. Rotemberg *et al.*, « A patient-centric dataset of images and metadata for identifying melanomas using clinical context », *Sci Data*, vol. 8, n° 1, Art. n° 1, janv. 2021, doi: [10.1038/s41597-021-00815-z](https://doi.org/10.1038/s41597-021-00815-z).
50. I. Talbi, « Comment gérer le déséquilibre des classes en machine learning ? », *La revue IA*, 8 mars 2021.  
<https://larevueia.fr/comment-gerer-le-desequilibre-des-classes-en-machine-learning/> (consulté le 28 août 2023).
51. J. Brownlee, « Random Oversampling and Undersampling for Imbalanced Classification », *MachineLearningMastery.com*, 14 janvier 2020.  
<https://machinelearningmastery.com/random-oversampling-and-undersampling-for-imbalanced-classification/> (consulté le 28 août 2023).
52. « Exploitez votre jeu de données », *OpenClassrooms*.  
<https://openclassrooms.com/fr/courses/4011851-initiez-vous-au-machine-learning/4020631-exploitez-votre-jeu-de-donnees> (consulté le 29 août 2023).
53. A. Rosebrock, « Change input shape dimensions for fine-tuning with Keras », *PyImageSearch*, 24 juin 2019.  
<https://pyimagesearch.com/2019/06/24/change-input-shape-dimensions-for-fine-tuning-with-keras/> (consulté le 29 août 2023).
54. J. Brownlee, « A Gentle Introduction to Transfer Learning for Deep Learning », *MachineLearningMastery.com*, 19 décembre 2017.  
<https://machinelearningmastery.com/transfer-learning-for-deep-learning/> (consulté le 29 août 2023).
55. L. Famiglini, « Transfer Learning with Deep Learning & Machine Learning techniques », *Medium*, 19 novembre 2019.

<https://medium.com/@lorenzofamigliani/transfer-learning-with-deep-learning-machine-learning-techniques-b4052befe7e2> (consulté le 29 août 2023).

56. S. R. Sapiroddy, « ResNet-50: Introduction », *Medium*, 1 juillet 2023.  
<https://srsapiroddy.medium.com/resnet-50-introduction-b5435fdb66f> (consulté le 30 août 2023).
57. « ResNet-50 convolutional neural network - MATLAB resnet50 ».  
<https://www.mathworks.com/help/deeplearning/ref/resnet50.html> (consulté le 30 août 2023).
58. K. Team, « Keras documentation: DenseNet ».  
<https://keras.io/api/applications/densenet/> (consulté le 30 août 2023).
59. S. Das, « Implementing DenseNet-121 in PyTorch: A Step-by-Step Guide », *deepkapha notes*, 19 mars 2023.  
<https://medium.com/deepkapha-notes/implementing-densenet-121-in-pytorch-a-step-by-step-guide-c0c2625c2a60> (consulté le 30 août 2023).
60. « Figure 3. Layered Architecture of DenseNet201. », *ResearchGate*.  
[https://www.researchgate.net/figure/Layered-Architecture-of-DenseNet201\\_fig3\\_342672764](https://www.researchgate.net/figure/Layered-Architecture-of-DenseNet201_fig3_342672764) (consulté le 31 août 2023).
61. « Pretrained Inception-ResNet-v2 convolutional neural network - MATLAB inceptionresnetv2 ».  
<https://www.mathworks.com/help/deeplearning/ref/inceptionresnetv2.html> (consulté le 10 septembre 2023).
62. « Figure 5. Schematic diagram of InceptionResNetV2 model (compressed view). », *ResearchGate*.  
[https://www.researchgate.net/figure/Schematic-diagram-of-InceptionResNetV2-model-compressed-view\\_fig9\\_326421398](https://www.researchgate.net/figure/Schematic-diagram-of-InceptionResNetV2-model-compressed-view_fig9_326421398) (consulté le 10 septembre 2023).
63. « Xception convolutional neural network - MATLAB xception ».  
<https://www.mathworks.com/help/deeplearning/ref/xception.html> (consulté le 10 septembre 2023).
64. Nutan, « Image Classification With Xception Model », *Medium*, 27 novembre 2021.  
<https://medium.com/@nutanbhogendrasharma/image-classification-with-xception-model-e8094a9de4d2> (consulté le 10 septembre 2023).

65. A. G. Howard *et al.*, « MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications ». arXiv, 16 avril 2017. doi: [10.48550/arXiv.1704.04861](https://doi.org/10.48550/arXiv.1704.04861).
66. « FIGURE 4. Proposed structure of Xception network used within each... », *ResearchGate*.  
[https://www.researchgate.net/figure/Proposed-structure-of-Xception-network-used-within-each-stream-of-CNN\\_fig2\\_355098045](https://www.researchgate.net/figure/Proposed-structure-of-Xception-network-used-within-each-stream-of-CNN_fig2_355098045) (consulté le 10 septembre 2023).
67. G. Alwakid, W. Gouda, M. Humayun, et N. U. Sama, « Melanoma Detection Using Deep Learning-Based Classifications », *Healthcare (Basel)*, vol. 10, n° 12, p. 2481, déc. 2022, doi: [10.3390/healthcare10122481](https://doi.org/10.3390/healthcare10122481).
68. S. Banerjee, S. K. Singh, A. Chakraborty, A. Das, et R. Bag, « Melanoma Diagnosis Using Deep Learning and Fuzzy Logic », *Diagnostics (Basel)*, vol. 10, n° 8, p. 577, août 2020, doi: [10.3390/diagnostics10080577](https://doi.org/10.3390/diagnostics10080577).
69. D. Bisla, A. Choromanska, J. A. Stein, D. Polsky, et R. Berman, « Towards Automated Melanoma Detection with Deep Learning: Data Purification and Augmentation ». arXiv, 14 mai 2019. doi: [10.48550/arXiv.1902.06061](https://doi.org/10.48550/arXiv.1902.06061).
70. C. Barata *et al.*, « A reinforcement learning model for AI-based decision support in skin cancer », *Nat Med*, vol. 29, n° 8, Art. n° 8, août 2023, doi: [10.1038/s41591-023-02475-5](https://doi.org/10.1038/s41591-023-02475-5).
71. « (PDF) Diagnosing Melanomas in Dermoscopy Images Using Deep Learning ». [https://www.researchgate.net/publication/370962392\\_Diagnosing\\_Melanomas\\_in\\_Dermoscopy\\_Images\\_Using\\_Deep\\_Learning](https://www.researchgate.net/publication/370962392_Diagnosing_Melanomas_in_Dermoscopy_Images_Using_Deep_Learning) (consulté le 31 août 2023).
72. A. Nambisan *et al.*, « Improving Automatic Melanoma Diagnosis Using Deep Learning-Based Segmentation of Irregular Networks », *Cancers*, vol. 15, p. 1259, févr. 2023, doi: [10.3390/cancers15041259](https://doi.org/10.3390/cancers15041259).
73. A. C. Foahom Gouabou *et al.*, « Computer Aided Diagnosis of Melanoma Using Deep Neural Networks and Game Theory: Application on Dermoscopic Images of Skin Lesions », *International Journal of Molecular Sciences*, vol. 23, p. 13838, nov. 2022, doi: [10.3390/ijms232213838](https://doi.org/10.3390/ijms232213838).
74. « Dark Corner on Skin Lesion Image Dataset: Does it matter? » <https://ieeexplore.ieee.org/document/9857121/> (consulté le 31 août 2023).

75. M. Nawaz *et al.*, « Skin cancer detection from dermoscopic images using deep learning and fuzzy k-means clustering », *Microscopy Research and Technique*, vol. 85, août 2021, doi: [10.1002/jemt.23908](https://doi.org/10.1002/jemt.23908).
76. « (PDF) Melanoma lesion detection and segmentation using deep region based convolutional neural network and fuzzy C-means clustering ». <http://msplab.uettaxila.edu.pk/wp-content/uploads/2022/06/Melanoma-lesion-detection.pdf>
77. H. Zunair et A. B. Hamza, « Melanoma Detection using Adversarial Training and Deep Transfer Learning », *Phys. Med. Biol.*, vol. 65, n° 13, p. 135005, juill. 2020, doi: [10.1088/1361-6560/ab86d3](https://doi.org/10.1088/1361-6560/ab86d3).
78. G. Nadjette, S. Zelikha, et C. Samira, « Etude et experimentation des réseaux resnet-50 et inception- v3 dans la classification de cancer de la peau », 2021, Consulté le: 2 septembre 2023. [En ligne]. Disponible sur: <http://localhost:8080/xmlui/handle/123456789/11201>
79. « Qu'est-ce que Python ? – Le langage Python expliqué – AWS », *Amazon Web Services, Inc.* <https://aws.amazon.com/fr/what-is/python/> (consulté le 3 septembre 2023).
80. « What is Python? Executive Summary », *Python.org*. <https://www.python.org/doc/essays/blurb/> (consulté le 3 septembre 2023).
81. « Wisdom of Crowds: Definition, Theory, Examples », *Investopedia*. <https://www.investopedia.com/terms/w/wisdom-crowds.asp> (consulté le 6 septembre 2023).
82. « Ensemble learning : définition, fonctionnement et algorithmes », 3 mai 2022. <https://www.journaldunet.fr/web-tech/guide-de-l-intelligence-artificielle/1501883-methode-ensembliste-ensemble-learning/> (consulté le 6 septembre 2023).
83. M. Waskom, « seaborn: statistical data visualization », *JOSS*, vol. 6, n° 60, p. 3021, avr. 2021, doi: [10.21105/joss.03021](https://doi.org/10.21105/joss.03021).
84. « Keras : une bibliothèque open source pour la constitution de réseaux neuronaux », *IONOS Digital Guide*, 8 octobre 2020.

<https://www.ionos.fr/digitalguide/web-marketing/search-engine-marketing/quest-ce-que-keras/> (consulté le 6 septembre 2023).

85. « Keras: Deep Learning for humans ». <https://keras.io/> (consulté le 6 septembre 2023).

86. « Matplotlib logo – Matplotlib 3.7.2 documentation ». <https://matplotlib.org/stable/gallery/misc/logos2.html> (consulté le 6 septembre 2023).

87. « TensorFlow ». <https://www.tensorflow.org/?hl=fr> (consulté le 6 septembre 2023).

88. « pandas - Python Data Analysis Library ». <https://pandas.pydata.org/about/citing.html> (consulté le 6 septembre 2023).

89. « The Python Logo | Python.org ». <https://staging.python.org/community/logos/> (consulté le 6 septembre 2023).

90. D. Team, « NumPy : la bibliothèque Python la plus utilisée en Data Science », *Formation Data Science | DataScientest.com*, 20 avril 2021. <https://datascientest.com/numpy> (consulté le 6 septembre 2023).

91. « What is NumPy? – NumPy v1.25 Manual ». <https://numpy.org/doc/stable/user/whatisnumpy.html> (consulté le 6 septembre 2023).

92. S. Yegulalp, « What is TensorFlow? The machine learning library explained », *InfoWorld*, 3 juin 2022. <https://www.infoworld.com/article/3278008/what-is-tensorflow-the-machine-learning-library-explained.html> (consulté le 6 septembre 2023).

93. K. Madan, « What is Matplotlib in Python? », *Scaler Topics*, 25 juillet 2022. <https://www.scaler.com/topics/matplotlib/matplotlib-in-python/> (consulté le 6 septembre 2023).

94. « About us », *scikit-learn*. <https://scikit-learn/stable/about.html> (consulté le 6 septembre 2023).

95. T. Srivastava, « 12 Important Model Evaluation Metrics for Machine Learning

- Everyone Should Know (Updated 2023) », *Analytics Vidhya*, 6 août 2019.  
<https://www.analyticsvidhya.com/blog/2019/08/11-important-model-evaluation-error-metrics/> (consulté le 7 septembre 2023).
96. C. Tremblay, « Matrice de confusion / Confusion matrix pour le Machine Learning », *Kobia*, 16 novembre 2021.  
<https://kobia.fr/classification-metrics-matrice-de-confusion/> (consulté le 7 septembre 2023).
97. T. Kanstrén, « A Look at Precision, Recall, and F1-Score », *Medium*, 4 août 2023.  
<https://towardsdatascience.com/a-look-at-precision-recall-and-f1-score-36b5fd0dd3ec> (consulté le 7 septembre 2023).
98. « Guide to AUC ROC Curve in Machine Learning », *GeeksforGeeks*, 25 novembre 2020. <https://www.geeksforgeeks.org/auc-roc-curve/> (consulté le 8 septembre 2023).
99. K. Team, « Keras documentation: Transfer learning & fine-tuning ». [https://keras.io/guides/transfer\\_learning/](https://keras.io/guides/transfer_learning/) (consulté le 8 septembre 2023).
100. « Google AI4Code Reconstruct the order ». <https://kaggle.com/code/corneliuskristianto/google-ai4code-reconstruct-the-order> (consulté le 9 septembre 2023).
101. B. Maurice, « Comprendre overfitting et underfitting », *Deeply Learning*, 15 septembre 2018.  
<https://deeplylearning.fr/cours-theoriques-deep-learning/comprendre-overfitting-et-underfitting/> (consulté le 10 septembre 2023).
102. « What is underfitting and overfitting in machine learning and how to deal with it. | by Anup Bhande | GreyAtom | Medium ». <https://medium.com/greyatom/what-is-underfitting-and-overfitting-in-machine-learning-and-how-to-deal-with-it-6803a989c76> (consulté le 10 septembre 2023).

103. « Melanoma Skin Cancer Dataset of 10000 Images ».  
<https://www.kaggle.com/datasets/hasnainjaved/melanoma-skin-cancer-dataset-of-10000-images> (consulté le 10 septembre 2023).
104. W. Abbes et D. Sellami, « Deep Neural Networks for Melanoma Detection from Optical Standard Images using Transfer Learning », *Procedia Computer Science*, vol. 192, p. 1304-1312, janv. 2021, doi: [10.1016/j.procs.2021.08.134](https://doi.org/10.1016/j.procs.2021.08.134).