



REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
MINISTRE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE SCIENTIFIQUE

UNIVERSITE IBN KHALDOUN - TIARET

MEMOIRE

Présenté à :

FACULTÉ DES MATHÉMATIQUES ET DE L'INFORMATIQUE
DÉPARTEMENT D'INFORMATIQUE

Pour l'obtention du diplôme de :

MASTER

Spécialité : Génie Informatique

Par :

BAGHDADI M'hamed
LAKEHAL Boucif

Sur le thème

Détection et classification du cancer de la peau par l'utilisation de l'apprentissage profond.

Soutenu publiquement le ..06/2024 à Tiaret devant le jury composé de :

Mr. BELARBI Mostefa	Grade	Université	Prof	Président
Mr. BAGHDADI Mohamed	Grade	Université	MCA	Encadrant
Mr. MEZZOUG Karim	Grade	Université	MAA	Examineur

2023 - 2024

Remerciements :

Nous remercions Dieu le Tout-Puissant de nous avoir donné la santé et la volonté d'entamer et de terminer ce mémoire.

Tout d'abord, ce travail ne serait pas aussi riche et n'aurait pas pu voir le jour sans l'aide et l'encadrement de Mr. Baghdadi Mohamed. Nous le remercions pour la qualité de son encadrement exceptionnel, pour sa patience, sa rigueur et sa disponibilité durant la préparation de ce mémoire.

Nous tenons également à remercier les membres du jury Mr. Belarbi mostefa et Mr. Mezzoug karim qui ont bien voulu lire et examiner notre travail. Un merci spécial à tous ceux qui nous ont soutenus pour terminer ce travail.

Dédicace :

Nous dédions ce modeste travail à l'ensemble de nos familles pour leur soutien indéniable et incontestable, pour leur amour inconditionnel en particulier, nos pères qui étaient les piliers sur lesquels on s'est appuyés tout au long de ce parcours pour y arriver à ce moment-là. Nos chères mères, la quintessence de l'amour, étaient le refuge de toutes les déceptions lors de ce parcours. À nos sœurs, nos frères, nos neveux et nos nièces.

Résumé

Les images médicales de la peau contiennent suffisamment d'informations pour déterminer si une lésion est cancéreuse ou non. Les médecins et les experts dans ce domaine ont adopté cette méthode en raison de la difficulté de mener des biopsies dans la plupart des cas pour diverses raisons. Le but de ce projet est de concevoir un système intelligent capable de distinguer les images médicales de la peau afin d'aider les médecins et de détecter automatiquement les cas de cancer de la peau. Le système proposé permet de classer une image en deux classes (image d'une lésion bénigne ou image d'une lésion maligne). Notre approche de détection du cancer de la peau est basée sur l'apprentissage profond, en particulier sur les réseaux de neurones convolutionnels (CNN). Ces réseaux ont prouvé leur capacité ces dernières années, notamment dans le domaine médical, en remportant le premier prix dans diverses compétitions dédiées à la classification des images médicales. Dans ce travail, nous avons développé un modèle CNN spécifique pour ce type de cancer. Notre modèle a donné des résultats satisfaisants.

Mots-clés: Deep Learning, Réseaux de neurones convolutifs, CNN, Images médicales, Cancer de la peau, TensorFlow, Keras.

Abstract

Medical skin images contain sufficient information to determine whether a lesion is cancerous or not. Physicians and experts in this field have adopted this method due to the difficulty of performing biopsies in most cases for various reasons. The goal of this project is to design an intelligent system capable of distinguishing medical skin images to assist physicians and automatically detect cases of skin cancer. The proposed system classifies an image into two categories (image of a benign lesion or image of a malignant lesion). Our approach to skin cancer detection is based on deep learning, particularly convolutional neural networks (CNN). These networks have proven their capability in recent years, especially in the medical field, by winning first place in various competitions dedicated to medical image classification. In this work, we have developed a specific CNN model for this type of cancer. Our model has yielded satisfactory results.

Keywords: Deep Learning, Convolutional Neural Networks, CNN, Medical Images, Skin Cancer, TensorFlow, Keras.

المخلص

تحتوي الصور الطبية للبشرة على معلومات كافية لتحديد ما إذا كانت الآفة سرطانية أم لا. تبنى الأطباء والخبراء في هذا المجال هذه الطريقة نظرًا لصعوبة إجراء الخزعات في معظم الحالات لأسباب متنوعة. الهدف من هذا المشروع هو تصميم نظام ذكي قادر على تمييز الصور الطبية للبشرة لمساعدة الأطباء واكتشاف حالات سرطان الجلد تلقائيًا. النظام المقترح يصنف الصورة إلى فئتين (صورة لآفة حميدة أو صورة لآفة خبيثة). تعتمد طريقتنا في الكشف عن سرطان الجلد على التعلم العميق، وبالأخص الشبكات العصبية الالتفافية (CNN). لقد أثبتت هذه الشبكات كفاءتها في السنوات الأخيرة، لا سيما في المجال الطبي، بفوزها بالمركز الأول في مسابقات متنوعة مخصصة لتصنيف الصور الطبية. في هذا العمل، قمنا بتطوير نموذج CNN خاص لهذا النوع من السرطان. لقد قدم نموذجنا نتائج مرضية.

الكلمات المفتاحية: التعلم العميق، الشبكات العصبية الالتفافية، الصور الطبية، سرطان الجلد، Keras , TensorFlow

TABLE DES MATIERES

Introduction générale.....	1
CHAPITRE 01 (Généralités sur le cancer de la peau)	
I.1 Introduction	4
I.2 Définition du terme "Peau".....	4
I.3 Composants de la peau.....	5
I.3.1 L'épiderme.....	5
I.3.2 Derme.....	6
I.3.3 hypoderme.....	7
I.4 Maladies cutanées non cancéreuses.....	7
I.4.1 Psoriasis	7
I.4.2 Eczéma.....	8
I.4.3 Lupus érythémateux disséminé	8
I.5 Cancer de la peau.....	9
I.6 Type de cancer de la peau.....	10
I.6.1 Carcinome basocellulaire (Carcinome basocellulaire CBC).....	10
I.6.2 Mélanome	10
I.6.3 Carcinome épidermoïde (Squamous-Cell Carcinoma SCC).....	11
I.7 Comment repérer un cancer de la peau.....	12
I.8 Signes et symptômes possibles du mélanome.....	12
I.9 Techniques d'imagerie du cancer de la peau.....	13
I.9.1 Microscopie confocale à réflectance (Reflectance confocal microscopy RCM).....	13
I.9.2 Tomographie par cohérence optique (Optical Coherence Tomography OCT)	14
I.9.3 Échographie.....	14
I.9.4 Dermoscopie	14
I.10 Conclusion	14

CHAPITRE 02 (Deep learning)

II.1 Introduction	17
II.2 Définition du deep learning.....	17
II.3 Domaines d'application du deep learning	17
II.4 Classification avec les réseaux de neurones.....	18
II.4.1 Définition d'un réseau neuronal	20
II.4.2 Neurone biologique	20
II.4.2.1 Cellule nerveuse	20
II.4.2.2 Corps cellulaire	21
II.4.2.3 Dendrites	21
II.4.2.4 Axone... ..	21
II.4.2.5 Transmission synaptique	21
II.4.3 Neurone artificiel	22
II.4.3.1 Réseaux "Feed-forward"	23
II.4.3.2 Réseaux "Feed-back".....	24
II.4.4 Apprentissage	24
II.4.4.1 Mode supervisé	25
II.4.4.2 Renforcement	25
II.4.4.3 Mode non-supervisé (ou auto-organisationnel)	25
II.4.4.4 Mode hybride.....	25
II.4.5 Neurone formel.....	25
II.4.5.1 Interprétation mathématique.....	26
II.4.5.2 Fonctions d'activation	26
II.4.6 Réseau de neurone multicouches (MLP).....	27
II.5 Réseaux de neurones profonds.....	29
II.5.1 Réseaux de neurones récurrents.....	30
II.5.2 Réseaux de neurones convolutifs	31
II.6 Détails sur les CNNs.....	32
II.6.1 Couche d'entrée.....	33

II.6.2 Couche de convolution	33
II.6.3 Couche de pooling.....	35
II.6.4 Couche d'activation.....	35
II.6.5 Couche Flatten.....	36
II.6.6 Couche complètement connectée	36
II.6.7 Couche de sortie (output layer)	37
II.6.8 Autres outils des CNNs.....	38
II.6.8.1 Fonction d'erreur.....	38
II.6.8.2 Dropout.....	38
II.6.8.3 Normalisation par lots.....	39
II.6.8.4 Arrêt anticipé.....	39
II.6.8.5 Augmentation des données.....	39
II.6.8.6 Apprentissage par transfert.....	40
II.6.8.7 Optimisation	40
II.7 Travaux Connexes sur la Détection du Cancer de la Peau en utilisant le Deep Learning	41
II.8 Conclusion	42

CHAPITRE 03 (Expériences et résultats)

III.1 Introduction	44
III.2 Environnement du travail	44
III.2.2 Langage de programmation Python.....	44
III.2.3 Google Colab.....	45
III.2.4 Navigateur Anaconda	45
III.2.5 Jupyter Notebook	46
III.2.6 Keras..	47
III.2.7 TensorFlow.....	47
III.2.8 OpenCV	47
III.2.9 Numpy	48
III.2.10 Pandas...	48
III.3 Dataset utilisée	49
III.4 Prétraitement et augmentation des données	49

III.5 Modèles de détection de cancer de la peau	52
III.5.1 Architecture de notre modèle 1 (modèle personnalisé).....	53
III.5.2 Modèles utilisant le transfer learning	55
III.5.2.1 Transfer learning avec VGG16 (Modèle 2).....	56
III.5.2.2 Transfer learning avec EfficientNet (Modèle 3)	57
III.6 Résultats obtenus avec notre modèle 1	58
III.6.1 Résultats d’entraînement et de validation de notre modèle 1	58
III.6.2 Résultats obtenus dans la phase de teste	59
III.7 Résultats obtenus avec notre modèle 2 (transfer learning avec VGG16)	61
III.8 Résultats obtenus avec notre modèle 3 (transfer learning avec EfficientNet)	61
III.9 Comparaison des différents résultats	62
III.10 Conclusion	62

Conclusion générale.....	63
Références bibliographiques.....	64

LISTE DES FIGURES

Figure I.1 : Composants de la peau [2].....	5
Figure I.2 : L'épiderme et les couches de derme dans la peau humaine avec des cellules squameuses, des cellules basales et des mélanocytes [5].....	6
Figure I.3: Image de la maladie du psoriasis [6].....	7
Figure I.4: Image de la maladie de l'eczéma. [6].....	8
Figure I.5: Image de la maladie du lupus érythémateux disséminé [6].	8
Figure I.6 : Image de cancer de la peau.....	9
Figure I.7 : Type de cancer - Carcinome basocellulaire (CBC) [8].....	10
Figure I.8 : Type de cancer – Mélanome [9].....	11
Figure I.9 : Type de cancer - Carcinome épidermoïde (SCC).....	12
Figure II.1: Relation entre l'intelligence artificielle, l'apprentissage automatique et l'apprentissage profond [15].....	17
Figure II.2 : Connexions inter neuronales chez l'humain [17]..	19
Figure II.3 : (a) Neurone biologique et (b) Neurone artificiel.....	19
Figure II.4 : Cellule nerveuse.....	20
Figure II.5 : Transmission synaptique.....	22
Figure II.6 : Neurone artificiel.....	23
Figure II.7 : Neurone formel.....	26
Figure II.8 : Représentation mathématique du neurone formel.....	26
Figure II.9 : Les fonctions d'activation : à seuil (a), par morceaux (b), des sigmoïdes (c) et des gaussiennes (d).....	27
Figure II.10 : Architecture d'un réseau de neurones avec une seule couche cachée..	27
Figure II.11 : Représentation d'un nœud dans un réseau MLP....	28
Figure II.12 : MLP avec une couche cachée.....	29
Figure II.13 : Architecture d'un réseau RNN.....	31
Figure II.14: Réseaux de neurones convolutifs.....	32
Figure II.15 : Différentes couches des CNNs.....	32
Figure II.16 : Trois dimensions d'image.....	33

Figure II.17 : Matrice d'entrée avec le filtre de convolution.....	34
Figure II.18 : Etapes de la convolution	34
Figure II.19 : Principe du filtre de convolution [27].....	34
Figure II.20 : Principe du Pooling [28].....	35
Figure II.21 : Architecture de la couche complètement connectée.....	36
Figure II.22: Exemple montrant l'étiquette codée de la couche de sortie CNN [29].....	37
Figure II.23 : Fonction softmax [30].....	38
Figure II.24 : Utilisation de l'arrêt anticipé dans la phase d'entraînement d'un modèle.....	39
Figure III.1 : Logo Python.....	45
Figure III.2 : Interface de google Colab.....	45
Figure III.3 : Navigateur Anaconda.....	46
Figure III.4: Jupyter notebook.....	46
Figure III.5: Logo Keras.....	47
Figure III.6: Logo TensorFlow.....	47
Figure III.7 Quelques images de notre dataset.....	49
Figure III.8 : Génération des deux classes d'entraînement et de test.....	50
Figure III.9: Exemple de prétraitement d'images.....	51
Figure III.10: Image cancéreuse prétraitée.....	51
Figure III.11: Exemple de deux images améliorées : image cancéreuse à droite et image non cancéreuse à gauche.....	52
Figure III.12 : Structure de base des CNNs.....	53
Figure III.13 : Architecture de notre modèle 1 (modèle personnalisé).....	55
Figure III.14 : Architecture du modèle de transfer learning avec VGG16.....	56
Figure III.15 : Différents composants et paramètres du modèle de transfer learning avec VGG16.....	57
Figure III.16 : Architecture du modèle de transfer learning avec EfficientNet.....	57
Figure III.17 : Différents composants et paramètres du modèle de transfer learning avec EfficientNet.....	58
Figure III.18 : Valeurs d'accuracy et de perte dans les phases d'entraînement et de validation pour notre modèle 1.....	59
Figure III.19: Classification d'une image aléatoire de la base de teste.....	60

Figure III.20: Matrice de confusion obtenue.....	60
Figure III.21 : Valeurs d'accuracy et de perte dans les phases d'entraînement et de validation pour notre modèle 2.....	61
Figure III.22 : Valeurs d'accuracy et de perte dans les phases d'entraînement et de validation pour notre modèle 3.....	61

Introduction Générale

La recherche en imagerie médicale est l'une des disciplines les plus actives en traitement d'images. Ses récentes découvertes permettent non seulement un meilleur diagnostic mais offrent aussi de nouveaux espoirs de traitement pour de nombreuses pathologies.

Le cancer de la peau est l'une des formes les plus courantes de cancer dans le monde. Il se manifeste principalement sous trois formes : le carcinome basocellulaire, le carcinome épidermoïde et le mélanome. Le mélanome est le plus dangereux des trois, car il est plus susceptible de se propager à d'autres parties du corps si non détecté tôt. Selon l'Organisation Mondiale de la Santé (OMS), environ 2 à 3 millions de cas de cancers non mélanomes et 132 000 cas de mélanomes malins sont diagnostiqués chaque année dans le monde.

La détection précoce et le diagnostic précis sont cruciaux pour améliorer le pronostic et la survie des patients atteints de cancer de la peau. Cependant, les méthodes traditionnelles de détection, comme les biopsies, peuvent être invasives, coûteuses et prennent du temps. En conséquence, il y a un besoin croissant de méthodes de diagnostic non invasives, rapides et précises.

L'objectif de ce projet est de concevoir un système intelligent capable de distinguer les images médicales de la peau afin d'aider les médecins et de détecter automatiquement les cas de cancer de la peau. Le système proposé classe une image en deux catégories : image d'une lésion bénigne ou image d'une lésion maligne. Notre approche de détection du cancer de la peau est basée sur l'apprentissage profond, en particulier sur les réseaux de neurones convolutionnels (CNN). Ces réseaux ont prouvé leur efficacité ces dernières années, notamment dans le domaine médical, en remportant des prix dans diverses compétitions dédiées à la classification des images médicales.

Le but principal de ce projet est de construire un système capable de détecter le cancer de la peau à partir des images médicales et de donner des décisions correctes avec un grand pourcentage de précision. Tout cela dépend de la qualité des données existantes, du réseau neuronal convolutif, du nombre de ses couches et de ses coefficients, et des couches utilisées pour traiter les données nécessaires à l'entraînement du réseau. Tous ces éléments sont traités dans ce projet à travers trois chapitres principaux.

Ce mémoire comprend trois chapitres :

- ✓ **Premier chapitre** : Nous parlerons du cancer de la peau, de ses différentes lésions, des moyens de sa détection et de son diagnostic, ainsi que du traitement d'images, en particulier des techniques d'imagerie du cancer de la peau.
- ✓ **Deuxième chapitre** : Nous présenterons l'apprentissage en profondeur et expliquerons l'architecture des réseaux neuronaux convolutionnels (Convolutional Neural Networks ou CNNs). Nous aborderons l'architecture d'un réseau neuronal convolutif et toutes ses propriétés telles que les couches, les fonctions, les optimiseurs et tous les paramètres qui contrôlent la qualité du réseau.
- ✓ **Troisième chapitre** : Nous décrirons notre modèle CNN proposé et notre application pour la classification des images médicales de la peau. Nous aborderons l'aspect de l'implémentation de ce projet et tous les moyens adoptés pour réaliser cette application, depuis l'environnement de développement et les bibliothèques utilisées jusqu'aux détails des tests et des résultats obtenus.

:

Chapitre 1

Généralités sur le cancer de la peau

I.1 Introduction

Le corps humain est une machine biologique très complexe, création de Dieu. Ce corps se compose de nombreux organes qui fonctionnent ensemble avec une grande précision. Lorsqu'un organe est affecté, d'autres organes peuvent également être impactés. La peau est considérée comme l'organe humain le plus important en termes de surface. Elle protège le corps des infections et des rayonnements ultraviolets (UV). Elle facilite le contrôle de la température corporelle et l'élimination des déchets organiques par la transpiration. Elle sert également à synthétiser la vitamine D et à stocker les réserves d'eau et de graisse [1].

Les organes du corps peuvent être touchés de plusieurs manières, soit par des causes physiques telles que des accidents et des blessures, soit par des raisons biologiques telles que des virus et des bactéries. Parmi les organes les plus sensibles du corps humain, on trouve la peau, qui peut être sujette à divers types de cancers. Le cancer de la peau est l'une des formes les plus courantes de cancer dans le monde. Il se manifeste principalement sous trois formes : le carcinome basocellulaire, le carcinome épidermoïde et le mélanome. Le mélanome est le plus dangereux des trois, car il est plus susceptible de se propager à d'autres parties du corps s'il n'est pas détecté tôt. Selon l'Organisation Mondiale de la Santé (OMS), environ 2 à 3 millions de cas de cancers non mélanomes et 132 000 cas de mélanomes malins sont diagnostiqués chaque année dans le monde.

Dans ce chapitre, nous allons explorer les généralités sur le cancer de la peau, en abordant ses différentes lésions, les moyens de sa détection, son diagnostic et son traitement. Nous mettrons également en lumière les techniques d'imagerie utilisées pour détecter le cancer de la peau et comment elles contribuent à un diagnostic plus précis et à un traitement plus efficace.

I.2 Définition du terme "Peau"

L'organe constituant la membrane externe du corps humain, composé de trois couches, l'épiderme, le derme et l'hypoderme, et soutenu par un tissu conjonctif. La peau est l'organe le plus lourd de l'organisme et sa surface est également supérieure à celle de tout autre organe. [2]

I.3 Composants de la peau

La peau, notre plus grand organe, est composée de trois couches principales : l'épiderme, le derme et l'hypoderme [2].

- **Épiderme** : C'est la couche la plus externe de la peau, visible et palpable. L'épiderme joue un rôle crucial dans la protection contre les toxines, les bactéries et la perte de fluides. Il est constitué de cinq sous-couches de kératinocytes.
- **Derme** : Située sous l'épiderme, le derme est une couche plus épaisse composée de tissu conjonctif. Il contient des vaisseaux sanguins, des glandes sudoripares et des follicules pileux, ainsi que des terminaisons nerveuses qui permettent la sensation de toucher et de température.
- **Hypoderme** : Également connu sous le nom de tissu sous-cutané, l'hypoderme est la couche la plus profonde de la peau. Elle est composée principalement de tissu adipeux et de cellules graisseuses, qui servent de réserve d'énergie et d'isolant thermique.

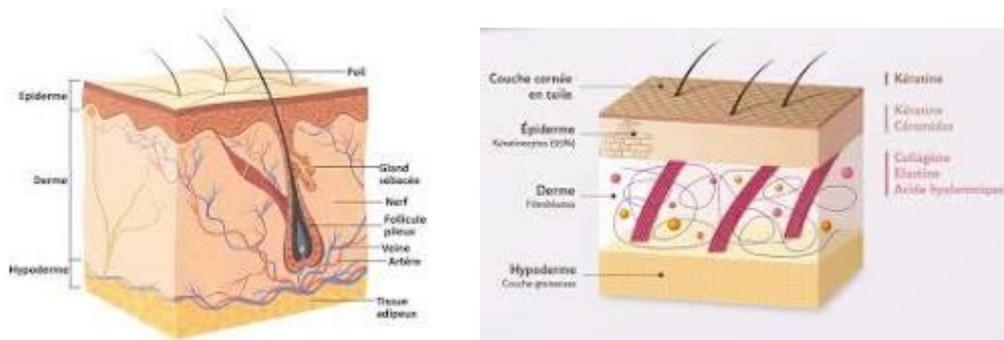


Figure I.1 : Composants de la peau [2].

I.3.1 L'épiderme

L'épiderme est la couche externe supérieure de la peau, composée de plusieurs types de cellules :

- **Cellules épidermoïdes** : Ces cellules plates sont étroitement compactées pour former la couche supérieure de la peau. Elles constituent la couche la plus épaisse de l'épiderme.
- **Cellules basales** : Ces cellules en forme de bloc constituent la couche inférieure de l'épiderme. Le corps fabrique constamment de nouvelles cellules basales. En

vieillissant, elles remontent dans l'épiderme et s'aplatissent pour former des cellules squameuses [3].

- **Mélanocytes** : Ces cellules se trouvent entre les cellules basales et produisent un pigment sombre appelé mélanine, qui donne à la peau sa couleur. Lorsque la peau est endommagée par les rayons ultraviolets (UV), les mélanocytes produisent de la mélanine supplémentaire. Ils se trouvent également dans des taches non cancéreuses sur la peau appelées grains de beauté ou naevi [4].

I.3.2 Derme

Cette couche de la peau se trouve sous l'épiderme. Le derme contient les racines des poils (follicules), des glandes sudoripares, des vaisseaux sanguins, des vaisseaux lymphatiques et les nerfs. Tous ces éléments sont maintenus en place par le collagène et l'élastine, deux protéines qui confèrent à la peau sa force et son élasticité. [5]

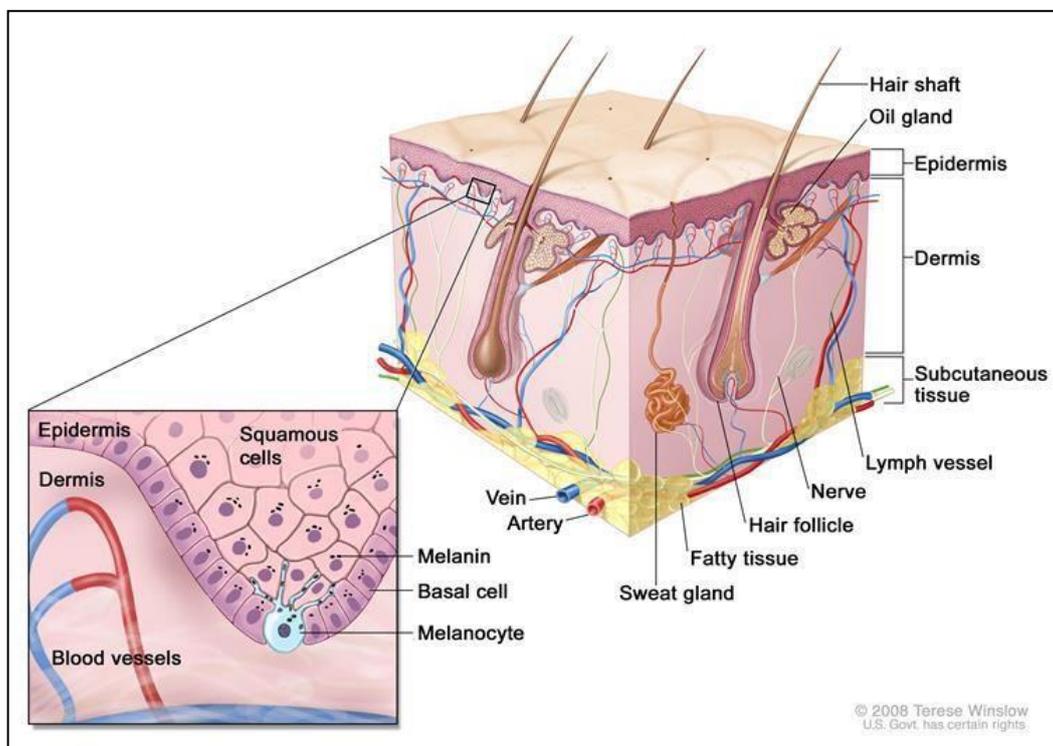


Figure I.2 : L'épiderme et les couches de derme dans la peau humaine avec des cellules squameuses, des cellules basales et des mélanocytes [5].

I.3.3 hypoderme

La couche interne de la peau est le tissu sous-cutané (ou hypoderme en anglais), constitué de tissu conjonctif lâche et de graisse. Cette couche est la plus épaisse au niveau des fesses, de la paume des mains et de la plante des pieds. Elle agit pour relier la peau aux tissus qui se trouvent en dessous, isoler le corps et soutenir et protéger les organes internes et les os.

L'intérieur de la peau est principalement constitué de tissu adipeux, un tissu conjonctif spécialisé composé de cellules adipeuses qui stockent la graisse pour isoler thermiquement le corps. Il contient également des vaisseaux sanguins, des vaisseaux lymphatiques, des follicules pileux, des nerfs et des globules blancs spécialisés appelés mastocytes. Ces derniers jouent un rôle dans la formation des vaisseaux sanguins, la cicatrisation des plaies et la protection du corps contre les agents pathogènes.

I.4 Maladies cutanées non cancéreuses

I.4.1 Psoriasis

Le psoriasis est une maladie cutanée courante qui perturbe le cycle de vie des cellules de la peau. En conséquence, les cellules psoriasiques se reproduisent de manière accélérée, s'accumulant rapidement à la surface de la peau pour former des plaques épaisses et squameuses de couleur argentée, souvent accompagnées de démangeaisons, de sécheresse et de rougeurs, parfois associées à des douleurs. [6]



Figure I.3: Image de la maladie du psoriasis [6].

I.4.2 Eczéma

L'eczéma est une affection cutanée provoquée par une dermatite atopique, caractérisée par une inflammation de la peau et une hypersensibilité allergique. Cette condition est souvent héritée, les facteurs génétiques jouant un rôle important dans son développement. [6]



Figure I.4: Image de la maladie de l'eczéma. [6].

I.4.3 Lupus érythémateux disséminé

Le lupus érythémateux disséminé est une maladie inflammatoire causée par un dysfonctionnement du système immunitaire, conduisant à une auto-immunité dans diverses parties du corps. Le nom de cette maladie est dérivé d'une éruption en forme de papillon qui apparaît sur les joues et le nez (érythème), ainsi que de l'inflammation systémique affectant de nombreux systèmes et organes du corps. [6]



Figure I.5: Image de la maladie du lupus érythémateux disséminé [6].

I.5 Cancer de la peau

Le corps humain est une entité complexe constituée de milliards de cellules vivantes qui constituent les tissus, les organes et les systèmes. Ces cellules ont une durée de vie limitée et subissent constamment un processus de renouvellement et de régénération pour maintenir la santé et la fonctionnalité des tissus. Ce processus implique la division cellulaire, au cours de laquelle une cellule mère se divise en deux cellules filles identiques.

La division cellulaire est un mécanisme vital pour le corps humain, car il permet le remplacement des cellules mortes ou endommagées, garantissant ainsi le bon fonctionnement des tissus et des organes. Cependant, ce processus est minutieusement régulé par des mécanismes internes de contrôle de la croissance cellulaire. Dans certains cas, des anomalies génétiques ou des facteurs environnementaux peuvent perturber ce contrôle et conduire à une croissance cellulaire anormale. Lorsque les cellules commencent à se multiplier de manière incontrôlée et ne répondent plus aux signaux de régulation, cela peut conduire à la formation d'une masse de tissu anormal, connue sous le nom de tumeur. Si cette tumeur devient maligne, elle peut envahir les tissus environnants et se propager à d'autres parties du corps, un processus appelé métastase. C'est à ce stade que la condition est considérée comme un cancer. Les cellules cancéreuses continuent de se diviser et de se propager de manière incontrôlable, perturbant les fonctions normales des tissus et des organes et pouvant mettre la vie en danger si elles ne sont pas traitées. Ainsi, bien que la division cellulaire soit un processus essentiel à la vie, son dysfonctionnement peut conduire au développement du cancer, mettant en lumière l'importance de la régulation précise de la croissance cellulaire pour maintenir la santé et prévenir les maladies [7].



Figure I.6 : Image de cancer de la peau.

I.6 Type de cancer de la peau

Les trois principaux types de cancer de la peau sont le carcinome basocellulaire (CBC), le carcinome épidermoïde (CSC) et le mélanome.

Le carcinome basocellulaire (BCC) et le carcinome épidermoïde (CSC) sont également appelés cancers de la peau non mélaniques ou cancers des kératinocytes.

Parmi les types rares de cancer de la peau autres que le mélanome, on trouve le carcinome des cellules de Merkel et l'angiosarcome. Ils sont traités différemment du BCC et du CSC.

I.6.1 Carcinome basocellulaire (Carcinome basocellulaire CBC)

Ce type de cancer commence dans les cellules basales de l'épiderme. Il représente environ 70% des cancers de la peau non mélaniques. Le CBC se développe lentement au fil des mois ou des années et se propage rarement dans d'autres parties du corps. Plus tôt un CBC est diagnostiqué, plus il est facile à traiter. S'il n'est pas traité, il peut s'enfoncer plus profondément dans la peau et endommager les tissus voisins, rendant ainsi le traitement plus difficile. Avoir un CBC augmente le risque d'en obtenir un autre. Il est possible d'avoir plus d'un CBC en même temps sur différentes parties du corps. [8]



Figure I.7 : Type de cancer - Carcinome basocellulaire (CBC) [8].

I.6.2 Mélanome

Ce type de cancer commence dans les cellules mélanocytaires de la peau. Il représente 1 à 2 % de tous les cancers de la peau. Bien que le mélanome soit moins courant que d'autres types de cancer de la peau, il est considéré comme le plus grave car il se propage rapidement et a le plus de chances de se métastaser vers d'autres parties du corps, telles que les ganglions

lymphatiques, les poumons, le foie, le cerveau et les os, s'il n'est pas détecté tôt. Plus le mélanome est détecté tôt, plus il est susceptible de répondre favorablement au traitement.

Le mélanome est l'un des types de cancer les plus meurtriers et qui se propage le plus rapidement dans le monde. Contrairement à d'autres cancers de la peau, le mélanome peut être mortel. Aux États-Unis, il est classé comme le sixième cancer le plus courant. Les appareils de bronzage ultraviolet sont répertoriés comme des agents cancérigènes humains connus et probables, aux côtés du plutonium et des cigarettes, par l'Organisation mondiale de la santé.

En 2017, environ 87 110 adultes ont été diagnostiqués avec un mélanome aux États-Unis, et environ 9 730 en sont décédés. La principale cause du mélanome est les dommages à l'ADN causés par l'exposition aux rayons UV, notamment par l'exposition au soleil et aux lits de bronzage. Les antécédents familiaux de mélanome et la peau claire sont également des facteurs de risque génétiques. [9]



Figure 1.8 : Type de cancer – Mélanome [9].

I.6.3 Carcinome épidermoïde (Squamous-Cell Carcinoma SCC)

Le carcinome épidermoïde commence dans les cellules squameuses de l'épiderme. Il représente environ 30 % des cancers cutanés non mélaniques. Le SCC a tendance à croître rapidement sur plusieurs semaines ou mois. S'il n'est pas traité, le SCC peut se propager dans d'autres parties du corps, ce qui est connu sous le nom de SCC invasif. Le CCS sur les lèvres et les oreilles est plus susceptible de se propager. [10]

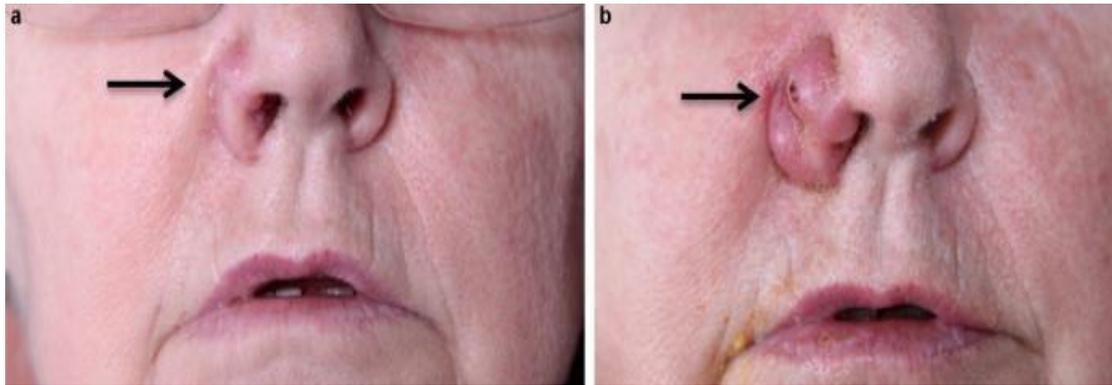


Figure I.9 : Type de cancer - Carcinome épidermoïde (SCC).

I.7 Comment repérer un cancer de la peau

Les cancers de la peau peuvent présenter divers aspects, mais il existe des signes à surveiller, notamment :

- Une zone qui semble différente et se sent différente des autres zones de la peau.
- Une zone qui a changé de taille, de forme, de couleur ou de texture.
- Une plaie qui ne guérit pas en quelques semaines.
- Une plaie qui démange ou qui saigne.

Il n'y a pas de règles strictes concernant la fréquence à laquelle rechercher un cancer de la peau, mais vérifier régulièrement votre peau vous aidera à repérer tout nouveau signe ou changement. Si vous avez déjà eu un cancer de la peau ou si vous présentez un risque accru, consultez votre médecin pour déterminer la fréquence idéale des auto-examens cutanés. [11]

I.8 Signes et symptômes possibles du mélanome

Le signe d'alerte le plus important du mélanome est l'apparition d'une nouvelle tache sur la peau ou d'une tache existante qui change de taille, de forme ou de couleur.

Un autre signe crucial est une lésion qui se distingue nettement des autres sur la peau (connu sous le nom de signe du "vilain petit canard").

Si vous observez l'un de ces signes précurseurs, consultez un médecin pour un examen cutané.

La règle ABCDE est un autre guide pour reconnaître les signes typiques du mélanome. Il faut faire attention aux lésions présentant l'une des caractéristiques suivantes :

- ✓ **A** signifie Asymétrie : la moitié d'une tache ou d'une tache de naissance ne correspond pas à l'autre.
- ✓ **B** signifie Bordure : les bords sont irréguliers, dentelés ou flous.

- ✓ **C** est pour la Couleur : la couleur n'est pas uniforme et peut inclure différentes nuances de brun ou de noir, ou parfois des taches roses, rouges, blanches ou bleues.
- ✓ **D** est pour le Diamètre : la lésion est plus grande que 6 millimètres de diamètre (environ ¼ de pouce - la taille d'une gomme à crayon), bien que les mélanomes puissent parfois être plus petits.
- ✓ **E** signifie Évolution : la lésion change de taille, de forme ou de couleur [11].

I.9 Techniques d'imagerie du cancer de la peau

S'il est diagnostiqué à un stade précoce, le cancer de la peau est traitable à 90 %, contre seulement 50 % aux stades avancés [12]. Avec le développement de techniques d'imagerie non invasives et à haute résolution, la précision du diagnostic des cancers cutanés ou des lésions cutanées a augmenté. En particulier, la moindre précision diagnostique du mélanome est la principale raison d'un surtraitement (causé par un faux diagnostic positif) ou d'un sous-traitement (causé par un faux diagnostic négatif). Un faux diagnostic positif est le principal facteur du coût de traitement, qui augmente en raison de l'excision d'un nombre inutilement élevé de lésions pour biopsie et examen pathologique. Cependant, les techniques d'imagerie à haute résolution ont un grand potentiel pour améliorer la spécificité du diagnostic et, par conséquent, introduire la possibilité de réduire les excisions inutiles et les coûts connexes.

Les techniques d'imagerie les plus couramment utilisées actuellement pour le diagnostic des cancers de la peau sont la microscopie confocale par réflectance, la tomographie par cohérence optique, l'échographie et la dermoscopie [13].

I.9.1 Microscopie confocale à réflectance (Reflectance confocal microscopy RCM)

La microscopie confocale est une méthode d'imagerie non invasive qui utilise un laser focalisé sur un point spécifique de la peau pour visualiser les détails cellulaires. En raison des différences d'indice de réfraction des structures cellulaires (cellules, mélanine, hémoglobine, etc.), la microscopie confocale peut facilement différencier la lumière réfléchi par la peau. Cependant, la microscopie confocale est la technique d'imagerie cutanée la plus coûteuse parmi les autres.

I.9.2 Tomographie par cohérence optique (Optical Coherence Tomography OCT)

L'OCT peut être utilisé pour imager des structures microscopiques et peut distinguer les tissus sains des tissus cancéreux. Cependant, l'OCT n'est pas capable de visualiser les éléments subcellulaires ni la membrane ; il ne peut pas détecter la tumeur à un stade précoce. De plus, sans confirmation histologique, l'OCT ne peut pas fournir un diagnostic complet du mélanome. Ainsi, l'OCT n'est pas un outil privilégié pour le processus de diagnostic du mélanome.

I.9.3 Échographie

L'échographie est l'une des procédures non invasives les plus courantes car elle est polyvalente, indolore et présente un faible risque. Au cours de cette procédure, la morphologie de la peau peut être visualisée par l'émission d'ondes ultrasonores qui rebondissent sur le tissu. Bien que les ondes ultrasonores puissent pénétrer les couches profondes de la peau et évaluer la tumeur, la faible résolution ne permet pas de distinguer morphologiquement les lésions cutanées. De plus, elle ne permet pas de détecter les tumeurs aux premiers stades.

I.9.4 Dermoscopie

La dermoscopie, également connue sous le nom de microscopie épiluminescente, est une méthode très pratique pour la détection précoce du mélanome malin et d'autres lésions pigmentées. Elle permet aux utilisateurs de capturer les couleurs et les structures profondes de la peau afin de détecter le mélanome à un stade précoce. Selon les statistiques de la littérature, l'utilisation de la dermoscopie peut augmenter la précision du diagnostic de 5% à 30% selon le type de lésions cutanées [14].

I.10 Conclusion

Ce chapitre met en lumière l'importance cruciale du diagnostic précoce dans la lutte contre cette maladie. Nous avons constaté que lorsque le cancer de la peau est détecté à un stade précoce, les chances de guérison sont considérablement élevées, atteignant jusqu'à 90%. Il est donc impératif pour chacun de surveiller régulièrement sa peau et de consulter un médecin dès l'apparition de nouveaux signes ou tâches suspectes. Par ailleurs, grâce aux progrès

réalisés dans les techniques d'imagerie à haute résolution, la précision du diagnostic localisé du cancer de la peau s'est améliorée, ouvrant la voie à la mise en place de programmes de dépistage plus efficaces et précis. En combinant une surveillance personnelle régulière avec l'utilisation de ces technologies avancées, nous pouvons espérer améliorer significativement la détection précoce et le traitement du cancer de la peau, offrant ainsi de meilleures perspectives de guérison et de survie pour les patients.

Chapitre 2

Deep learning

II.1 Introduction

L'apprentissage profond (ou deep learning en anglais) est une branche de l'apprentissage automatique (figure II.1) qui repose entièrement sur les réseaux de neurones artificiels, simulant le fonctionnement du cerveau humain. L'apprentissage profond est donc également une forme de simulation du cerveau humain. Bien que le concept d'apprentissage profond ne soit pas nouveau et existe depuis plusieurs années, il suscite beaucoup d'engouement aujourd'hui en raison des avancées significatives en puissance de traitement et en disponibilité des données au cours des 20 dernières années. Ces progrès ont fait de l'apprentissage profond un sujet de recherche très actif dans divers domaines, en particulier dans le domaine médical.

Dans ce chapitre, nous allons détailler le domaine de l'apprentissage profond, en mettant particulièrement l'accent sur les réseaux de neurones convolutifs, qui constituent le cœur de notre approche pour la détection du cancer de la peau.

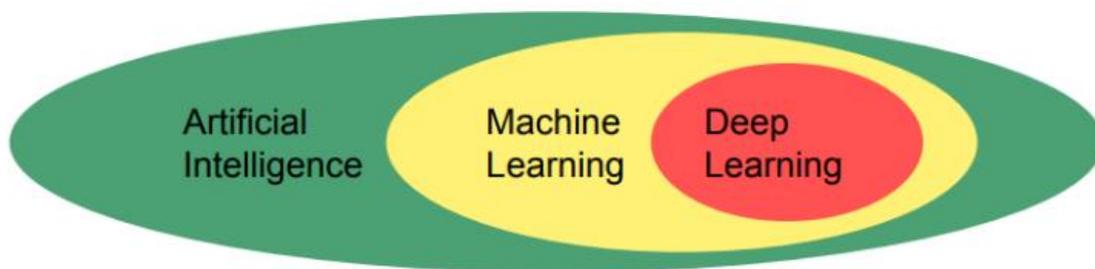


Figure II.1: Relation entre l'intelligence artificielle, l'apprentissage automatique et l'apprentissage profond [15].

III.2 Définition du deep learning

Le deep learning est l'un des principaux éléments de la science des données. C'est un sous-domaine de l'intelligence artificielle (IA) et de l'apprentissage automatique (machine learning) qui permet aux ordinateurs de comprendre le monde en imitant la manière dont les humains analysent les informations, en utilisant des algorithmes qui simulent le fonctionnement du cerveau, avec ou sans supervision humaine.

II.3 Domaines d'application du deep learning

La technologie d'apprentissage en profondeur est l'une des techniques les plus utilisées dans de nombreux domaines :

Reconnaissance faciale : Elle consiste à fournir un certain nombre d'images à l'algorithme. Avec suffisamment d'entraînement, l'algorithme peut détecter un visage sur une image.

Traitement automatique du langage naturel : Cette application du deep learning vise à extraire le sens des mots ou des phrases pour faire de l'analyse de sentiments.

Voitures autonomes : Les entreprises développant des systèmes d'aide à la conduite doivent apprendre à un ordinateur à maîtriser certaines parties essentielles de la conduite à l'aide de capteurs numériques, plutôt que l'esprit humain. Cela se fait généralement en entraînant des algorithmes avec une grande quantité de données.

Recherche vocale et assistants à commande vocale : L'un des domaines d'utilisation les plus populaires du deep learning est la recherche vocale et les assistants intelligents à commande vocale. Les grands géants de la technologie, comme Google et Facebook, ont déjà fait d'importants investissements dans ce domaine.

Traduction automatique : Cette tâche consiste à traduire automatiquement des mots, expressions ou phrases d'une langue à une autre. Bien que la traduction automatique existe depuis longtemps, le deep learning a permis d'obtenir de meilleurs résultats dans des domaines spécifiques comme la traduction automatique de textes et d'images.

Recherche en marketing : En plus de rechercher de nouvelles fonctionnalités susceptibles d'améliorer une application, le deep learning peut également être utile en arrière-plan. La segmentation du marché, l'analyse des campagnes marketing, et bien d'autres aspects peuvent être améliorés grâce à des modèles de régression et de classification. [16].

II.4 Classification avec les réseaux de neurones

Datant de millions d'années d'existence, le cerveau humain est la machine de traitement de l'information la plus performante. En effet, la lecture d'un texte, la reconnaissance d'un visage ou la résolution d'un problème (prise de décision) sont des opérations propres au cerveau.

L'élément de base constituant le cerveau est le neurone (nom attribué par les biologistes à cet élément) (voir figure II.2).

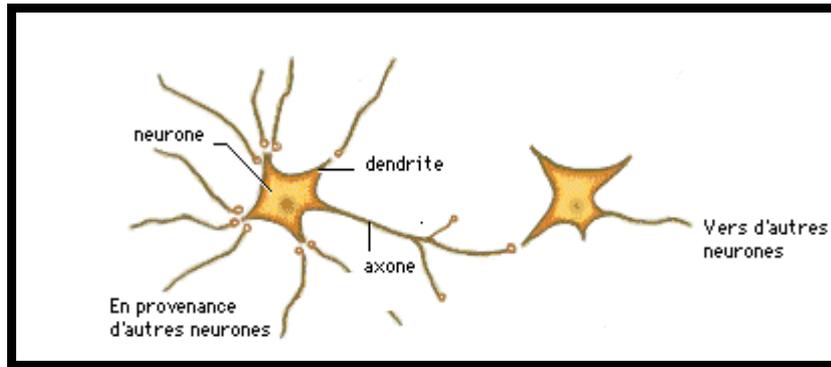


Figure II.2 : Connexions inter neuronales chez l'humain [17].

L'activité collective et simultanée des milliards de ces neurones, ou cellules nerveuses, confère au cerveau des capacités inaccessibles aux ordinateurs, même les plus puissants. Pourtant, chaque neurone effectue une opération simple sur l'ensemble des signaux qu'il reçoit des autres neurones via les dendrites. En effet, selon l'intensité de ces signaux, le neurone décide d'envoyer ou non un signal à ses congénères le long de son axone. La communication entre axones et dendrites s'effectue à des points appelés synapses.

Le réseau de neurones artificiels est une architecture inspirée par le fonctionnement du cerveau. La figure II.3 présente les réseaux neuronaux biologiques et artificiels.

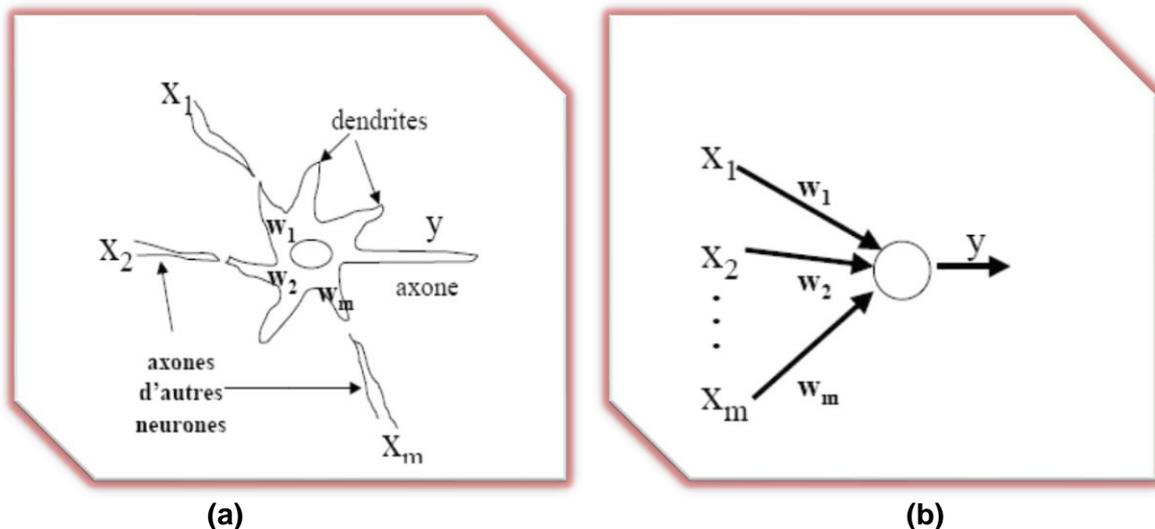


Figure II.3 : (a) Neurone biologique et (b) Neurone artificiel.

Dans cette section, nous dresserons un aperçu général de ce type d'architecture. Nous présenterons en particulier la modélisation d'un neurone biologique, puis nous détaillerons différentes architectures basées sur ce modèle.

II.4.1 Définition d'un réseau neuronal

Un réseau neuronal peut être vu comme un modèle du fonctionnement d'une partie du cerveau, composé d'environ 10^{11} cellules appelées neurones. Ces neurones sont connectés les uns aux autres par des liens entre l'axone d'un neurone et la dendrite d'un autre. On estime qu'un cerveau humain comporte environ 10^{15} de ces liens inter-neuronaux. L'axone est un prolongement du neurone émetteur qui transmet un signal à la dendrite du neurone récepteur. Il existe des liens forts entre certains neurones et des liens plus faibles entre d'autres. Lorsque la quantité combinée de matériel chimique provenant des différents axones atteint un certain seuil, le neurone récepteur émet à son tour un signal de sortie via son axone, destiné aux autres neurones auxquels il est connecté.

II.4.2 Neurone biologique

Les humains peuvent traiter divers types d'informations beaucoup plus rapidement que les machines. Par exemple, comprendre le langage parlé ou reconnaître des objets dans une scène visuelle prend quelques centaines de millisecondes pour le cerveau, tandis que cela prendrait beaucoup plus de temps pour un ordinateur, même si l'opération est possible.

Les unités de calcul de base du cerveau humain (les neurones) fonctionnent à une vitesse de calcul de base de quelques millisecondes, ce qui est beaucoup plus lent que les transistors dans un ordinateur moderne.

II.4.2.1 Cellule nerveuse

Le type le plus courant de neurone biologique se présente sous la forme d'une cellule dotée de deux types de prolongements (voir figure II.4) : (1) Des ramifications courtes et buissonnantes appelées dendrites, (2) une longue fibre se terminant par une arborisation appelée axone.

Ces prolongements permettent au neurone d'établir des connexions avec d'autres cellules nerveuses (ou avec des cellules musculaires dans le cas des neurones moteurs). [17]

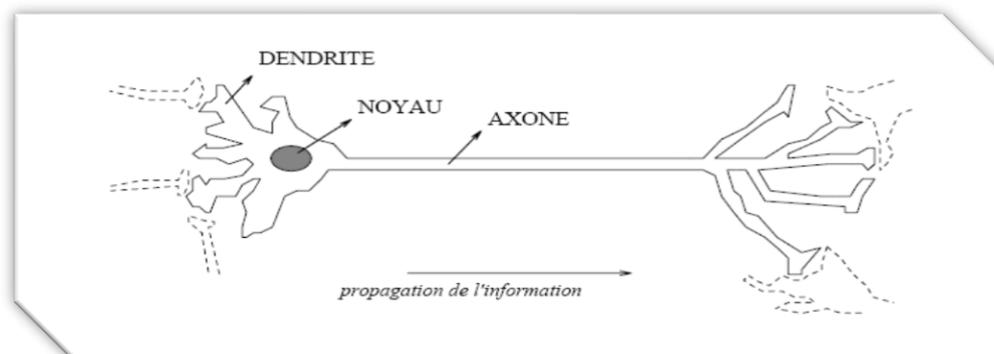


Figure II.4 : Cellule nerveuse.

II.4.2.2 Corps cellulaire

Le corps cellulaire contient le noyau du neurone ainsi que la machinerie biochimique nécessaire à la synthèse des enzymes. Ce corps cellulaire, de forme sphérique ou pyramidale, renferme également les autres molécules essentielles à la vie de la cellule. Sa taille est de quelques microns de diamètre.

II.4.2.3 Dendrites

Ce sont de fines extensions tubulaires qui se ramifient autour du neurone et forment une sorte de vaste arborescence. Les signaux envoyés au neurone sont captés par les dendrites. Leur taille est de quelques dizaines de micromètres de longueur.

II.4.2.4 Axone

C'est le long de l'axone que les signaux partent du neurone. Contrairement aux dendrites qui se ramifient autour du neurone, l'axone est plus long et se ramifie à son extrémité où il se connecte aux dendrites des autres neurones. Sa taille peut varier entre quelques millimètres à plusieurs mètres.

II.4.2.5 Transmission synaptique

Comment se fait la transmission de l'influx nerveux lorsqu'il arrive à une extrémité de l'axone (synapse) ? Les expériences montrent que les cas de transmission électrique sont rares. Généralement, la transmission met en œuvre des processus chimiques par l'intermédiaire de molécules organiques : les neuromédiateurs.

La terminaison synaptique contient des vésicules de neuromédiateurs (voir figure II.5). L'arrivée de l'onde de dépolarisation provoque une augmentation de la perméabilité de la membrane aux neuromédiateurs. Ceux-ci se trouvent donc libérés dans l'espace intersynaptique, et viennent se fixer sur des récepteurs chimiques situés sur le neurone cible. Lorsque ces récepteurs captent des neuromédiateurs, ils provoquent une augmentation de la perméabilité de la membrane du neurone cible aux ions sodium.

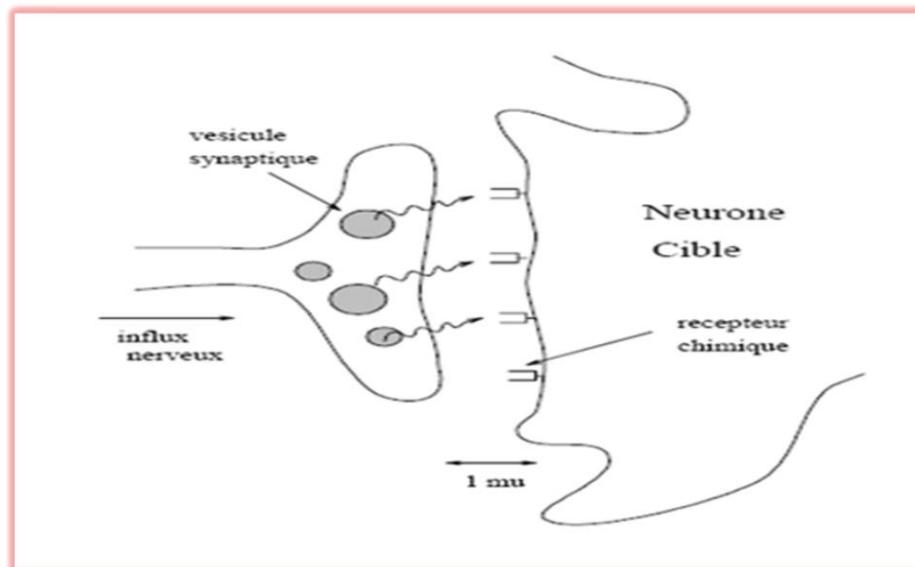


Figure II.5 : Transmission synaptique.

II.4.3 Neurone artificiel

Un réseau de neurones artificiels (RNA) est un ensemble de neurones formels (d'unités de calcul simples, de nœuds processeurs) associés en couches (ou sous-groupes) et fonctionnant en parallèle (voir figure II.6).

Dans un réseau, chaque sous-groupe effectue un traitement indépendant des autres et transmet le résultat de son analyse au sous-groupe suivant. L'information donnée au réseau se propage donc couche par couche, de la couche d'entrée à la couche de sortie, en passant par une ou plusieurs couches intermédiaires (dites couches cachées). Il est à noter qu'en fonction de l'algorithme d'apprentissage, il est aussi possible d'avoir une propagation de l'information en sens inverse (« backpropagation »). Habituellement (à l'exception des couches d'entrée et de sortie), chaque neurone dans une couche est connecté à tous les neurones de la couche précédente et de la couche suivante.

Les RNA ont la capacité de stocker des connaissances empiriques et de les rendre disponibles à l'usage. Les capacités de traitement (et donc les connaissances) du réseau sont stockées dans les poids synaptiques, obtenus par des processus d'adaptation ou d'apprentissage.

En ce sens, les RNA ressemblent au cerveau, car la connaissance est acquise par l'apprentissage et est stockée dans les connexions entre les entités, notamment dans les poids synaptiques.[18]

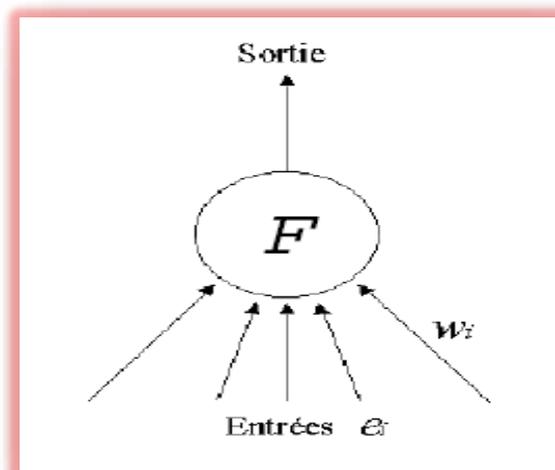


Figure II.6 : Neurone artificiel.

On peut classer les RNA en deux grandes catégories : les réseaux "feed-forward" et les réseaux "feedback".

II.4.3.1 Réseaux "Feed-forward"

Appelés aussi "réseaux de type Perceptron", ce sont des réseaux dans lesquels l'information se propage de couche en couche sans retour en arrière possible. Ils sont divisés en trois classes :

Le perceptron monocouche : C'est historiquement le premier RNA, c'est le Perceptron de Rosenblatt. Il s'agit d'un réseau simple, composé uniquement d'une couche d'entrée et d'une couche de sortie. Il est initialement basé sur le système visuel et a été conçu principalement pour la reconnaissance de formes. Cependant, il peut également être utilisé pour la classification et pour résoudre des opérations logiques simples telles que "ET" ou "OU". Sa principale limite est qu'il ne peut résoudre que des problèmes linéairement séparables. En général, il suit un processus d'apprentissage supervisé selon la règle de correction de l'erreur.

Le perceptron multicouche (PMC) : Le perceptron multicouche (PMC) est une extension du précédent, avec une ou plusieurs couches cachées entre l'entrée et la sortie. Chaque neurone dans une couche est connecté à tous les neurones de la couche précédente et de la couche suivante (à l'exception des couches d'entrée et de sortie), et il n'y a pas de connexions entre les cellules d'une même couche. Les fonctions d'activation utilisées dans ce type de réseaux sont principalement les fonctions à seuil ou sigmoïdes. Il peut résoudre des problèmes non-linéairement séparables et des problèmes logiques plus complexes, y compris le fameux

problème du XOR. Il suit également un processus d'apprentissage supervisé selon la règle de correction de l'erreur.

Les réseaux à fonction radiale : Ce sont les réseaux que l'on nomme aussi RBF. L'architecture est la même que pour les PMC cependant, les fonctions de base utilisées ici sont des fonctions Gaussiennes. Les RBF seront donc employés dans les mêmes types de problèmes que les PMC à savoir, en classification et en approximation de fonctions, particulièrement. L'apprentissage le plus utilisé pour les RBF est le mode hybride et les règles sont soit, la règle de correction de l'erreur soit, la règle d'apprentissage par compétition. .[18]

II.4.3.2 Réseaux "Feed-back"

Appelés aussi "réseaux récurrents", ce sont des réseaux dans lesquels il y a un retour en arrière de l'information.

Les cartes auto-organisatrices de Kohonen : Ce sont des réseaux à apprentissage non-supervisé qui établissent une carte discrète, ordonnée topologiquement, en fonction de patterns d'entrée. Le réseau forme ainsi une sorte de treillis dont chaque nœud est un neurone associé à un vecteur de poids. La correspondance entre chaque vecteur de poids est calculée pour chaque entrée. Par la suite, le vecteur de poids ayant la meilleure corrélation, ainsi que certains de ses voisins, vont être modifiés afin d'augmenter encore cette corrélation.

Les réseaux de Hopfield : Ce sont des réseaux récurrents et entièrement connectés. Dans ce type de réseau, chaque neurone est connecté à chaque autre neurone et il n'y a aucune différenciation entre les neurones d'entrée et de sortie. Ils fonctionnent comme une mémoire associative non linéaire et sont capables de trouver un objet stocké en fonction de représentations partielles ou bruitées. L'application principale des réseaux de Hopfield est l'entrepôt de connaissances mais aussi la résolution de problèmes d'optimisation. Le mode d'apprentissage utilisé ici est le mode non-supervisé. .[18]

II.4.4 Apprentissage

Pour un RNA, l'apprentissage peut être considéré comme le problème de la mise à jour des poids des connexions au sein du réseau, afin de réussir la tâche qui lui est demandée. L'apprentissage est la caractéristique principale des RNA et il peut se faire de différentes manières et selon différentes règles. Il existe quatre types d'apprentissage :

II.4.4.1 Mode supervisé

Dans ce type d'apprentissage, le réseau s'adapte en comparant le résultat qu'il a calculé, en fonction des entrées fournies, avec la réponse attendue en sortie. Ainsi, le réseau se modifie jusqu'à ce qu'il trouve la bonne sortie, c'est-à-dire celle attendue, correspondant à une entrée donnée.

II.4.4.2 Renforcement

Le renforcement est en fait une forme d'apprentissage supervisé, et certains auteurs le classent d'ailleurs dans la catégorie des modes supervisés. Dans cette approche, le réseau doit apprendre la corrélation entre l'entrée et la sortie en estimant son erreur, c'est-à-dire le rapport échec/succès. Le réseau va donc chercher à maximiser un indice de performance qui lui est fourni, appelé signal de renforcement. Le système est capable de déterminer si la réponse qu'il fournit est correcte ou non, mais il ne connaît pas la bonne réponse.

II.4.4.3 Mode non-supervisé (ou auto-organisationnel)

Dans ce cas, l'apprentissage est basé sur des probabilités. Le réseau se modifie en fonction des régularités statistiques de l'entrée et établit des catégories en attribuant et en optimisant une valeur de qualité aux catégories reconnues.

II.4.4.4 Mode hybride

Le mode hybride combine en fait les deux autres approches, car une partie des poids est déterminée par l'apprentissage supervisé et l'autre partie par l'apprentissage non-supervisé.

II.4.5 Neurone formel

Le premier neurone formel est apparu en 1943 grâce aux deux scientifiques Mac Culloch et Pitts (figure II.7). Le neurone formel est une modélisation mathématique qui reprend les principes du fonctionnement du neurone biologique, en particulier la sommation des entrées. Sachant qu'au niveau biologique, les synapses n'ont pas toutes la même valeur (les connexions entre les neurones étant plus ou moins fortes), les auteurs ont donc créé un algorithme qui pondère la somme de ses entrées par des poids synaptiques (coefficients de pondération). De plus, les valeurs 1 et -1 en entrée sont utilisées pour représenter une synapse excitatrice ou inhibitrice.

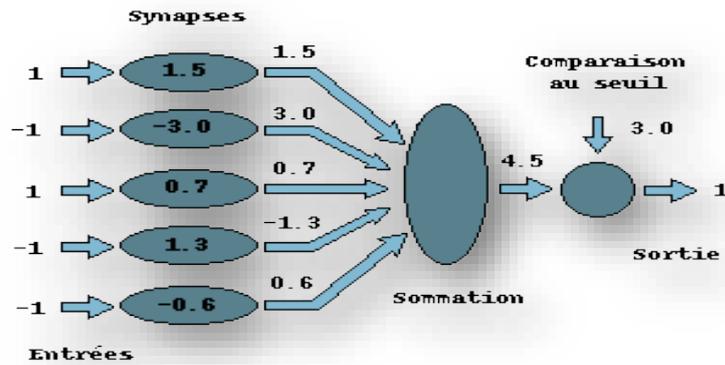


Figure II.7 : Neurone formel.

II.4.5.1 Interprétation mathématique

D'un point de vue mathématique, le neurone formel peut être représenté de la manière suivante [19] :

Pour un nombre quelconque j ($j = 1, \dots, n$), le neurone formel va calculer la somme pondérée de ses entrées (x_1, \dots, x_n) par les poids synaptiques correspondants (w_1, \dots, w_n) et la comparer à son seuil. Si le résultat est supérieur ou égal au seuil, alors la valeur renvoyée est 1 ; sinon, la valeur renvoyée est 0. Ainsi, la formule est représentée par la fonction seuil (f) :

$$y = f \sum_{j=1}^n w_j x_i - \theta \tag{II.1}$$

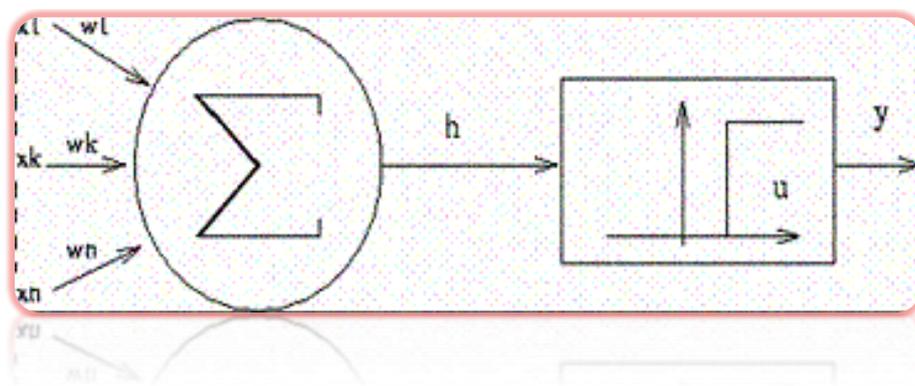


Figure II.8 : Représentation mathématique du neurone formel.

II.4.5.2 Fonctions d'activation

Dans sa première version, le neurone formel était implémenté avec une fonction à seuil (figure II.9a), mais de nombreuses versions existent. Ainsi, le neurone de McCulloch et Pitts a été généralisé de différentes manières, en choisissant d'autres fonctions d'activation, telles

que les fonctions linéaires par morceaux (figure II.9b), des sigmoïdes (figure II.9c) ou des gaussiennes (figure II.9d), par exemple [19].

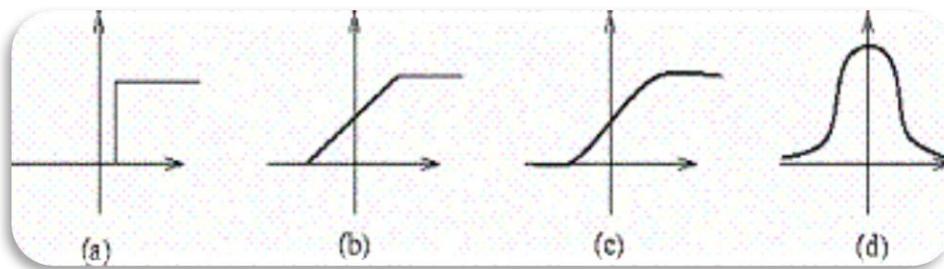


Figure II.9 : Les fonctions d'activation : à seuil (a), par morceaux (b), des sigmoïdes (c) et des gaussiennes (d).

II.4.6 Réseau de neurone multicouches (MLP)

Le réseau de neurones multicouches (Multi Layer Perceptron ou MLP) est un modèle créé pour imiter les fonctions d'apprentissage du cerveau humain. Dans les réseaux neuronaux, les neurones sont regroupés en couches, appelées couches neuronales. Habituellement, chaque neurone d'une couche est connecté à tous les neurones de ses couches précédentes et suivantes (à l'exception de l'entrée et de la sortie). L'information transmise dans un réseau de neurones se déplace de couche en couche, de l'entrée à la sortie, pouvant passer ou non à travers une ou plusieurs couches cachées. Selon l'algorithme utilisé, l'information peut également être propagée en arrière (rétro-propagation). La figure II.10 montre un réseau neuronal avec une couche cachée [20].

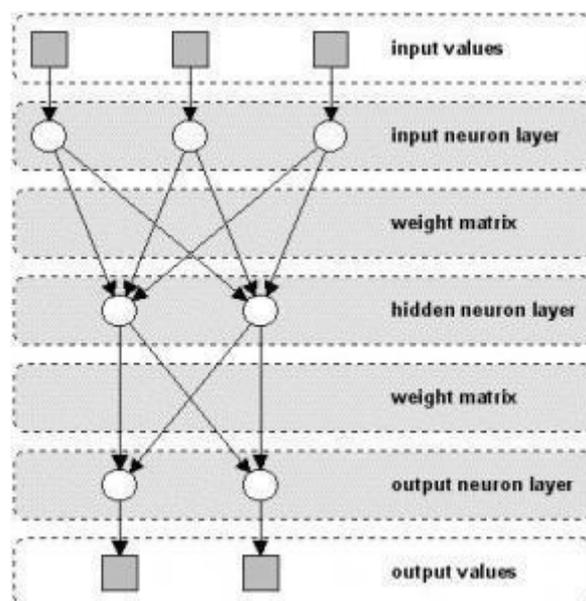


Figure II.10 : Architecture d'un réseau de neurones avec une seule couche cachée.

Le réseau de neurones multicouches est un type de réseau de neurones très populaire qui produit généralement de bons résultats en classification. Le MLP comprend une couche d'entrée, plusieurs couches cachées et une couche de sortie. La figure II.11 donne un aperçu de l'architecture d'un seul nœud du réseau MLP, où le point i représente le numéro de neurone dans le réseau et g sa fonction d'activation.

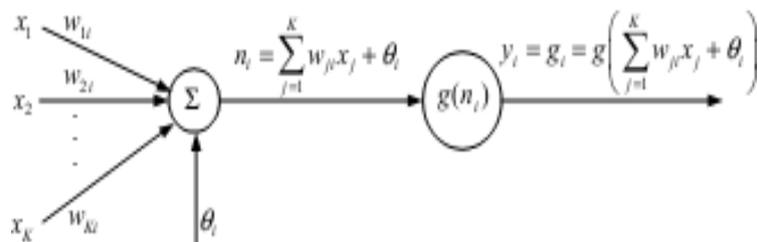


Figure II.11 : Représentation d'un nœud dans un réseau MLP

Avec x_k , $k=1, \dots, K$ comme entrée du modèle, w comme la matrice des poids et θ comme le biais. Le résultat n_i est une entrée pour activer la fonction d'activation g . Il existe plusieurs fonctions d'activation, mais les deux couramment utilisées en MLP sont la fonction tangente hyperbolique (\tanh) et la fonction sigmoïde. Les tangentes hyperboliques sont définies comme suit :

$$\tanh(x) = \frac{1 - e^{-x}}{1 + e^{-x}} \quad (\text{II.2})$$

Ainsi, le point de sortie devient comme ceci :

$$y_i = g_i = g \left(\sum_{j=1}^k w_{ji} x_j + \theta_i \right) \quad (\text{II.3})$$

En connectant plusieurs sorties en série et en parallèle, le réseau MLP sera entraîné comme le montre la figure II.12.

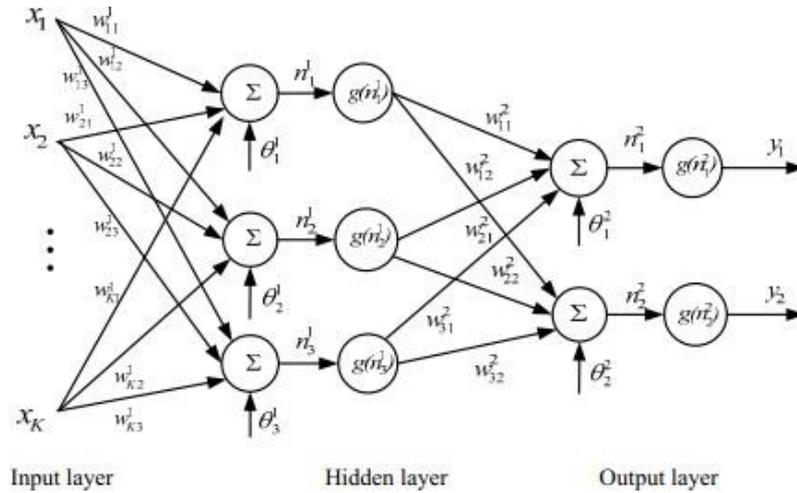


Figure II.12 : MLP avec une couche cachée.

La sortie $y_i, i=1,2$, du MLP de la figure II.12 est donnée comme suit :

$$y_i = g \left(\sum_{j=1}^3 w_{ji}^2 g(n_j^1) + \theta_j^2 \right) = g \left(\sum_{j=1}^3 w_{ji}^2 g \left(\sum_{k=1}^K w_{kj}^1 x_k + \theta_j^1 \right) + \theta_j^2 \right) \quad (\text{II.4})$$

À partir de l'équation ci-dessus, on peut conclure que le réseau MLP est un réseau avec des paramètres non linéaires. Les paramètres sont les poids w_k et les biais θ_k . La fonction d'activation g est généralement supposée être la même sur chaque couche.

À partir de l'équation ci-dessus, on peut conclure que le réseau MLP est un réseau avec des paramètres non linéaires. Les paramètres sont les poids w_k et les biais θ_k . La fonction d'activation g est généralement supposée être la même sur chaque couche [20].

II.5 Réseaux de neurones profonds

Les réseaux de neurones ne sont pas de nouveaux modèles. En effet, ils ont été introduits dès les années 1950. Le perceptron a été présenté en 1958 [21]. Ils connaissent actuellement leur heure de gloire grâce aux architectures profondes (deep learning) et à la puissance de calcul offerte par les GPU. Les méthodes basées sur les réseaux de neurones profonds sont classées en deux grandes familles : les méthodes supervisées et les méthodes non supervisées.

Les méthodes non supervisées traitent principalement des données non étiquetées, permettant au modèle de découvrir des modèles et des informations qui n'avaient pas été identifiés auparavant de manière autonome. La différence entre les méthodes supervisées et le groupage (clustering) est que le groupage est appliqué de manière non supervisée, de sorte qu'aucune

étiquette de classe n'est fournie, et parfois même le nombre de clusters n'est pas connu à l'avance.

Les méthodes supervisées utilisent des ensembles de données étiquetés pour entraîner des algorithmes permettant de classer les données ou de prédire les résultats avec précision. Au fur et à mesure que les données d'entrée sont introduites dans le modèle, celui-ci ajuste ses poids jusqu'à ce que le modèle soit ajusté de manière appropriée, ce qui se produit dans le cadre du processus de validation croisée. L'apprentissage supervisé aide à résoudre une variété de problèmes réels à grande échelle. Les architectures les plus connues dans l'apprentissage supervisé sont les réseaux de neurones convolutifs et les réseaux de neurones récurrents.

II.5.1 Réseaux de neurones récurrents

Un réseau de neurones récurrents (RNN) est une classe de réseaux de neurones artificiels où les connexions entre les nœuds forment un graphe orienté le long d'une séquence temporelle, lui permettant de présenter un comportement dynamique temporel.

L'idée derrière les RNNs est d'utiliser des informations séquentielles. Par exemple, pour prédire le prochain mot dans une phrase, il est nécessaire de connaître les mots qui le précèdent. Ces réseaux utilisent une mémoire qui capture les informations calculées précédemment. En théorie, les RNNs peuvent utiliser des informations en séquence sur des longueurs arbitraires, mais en pratique, ils se limitent souvent à ne regarder que quelques pas en arrière. Les RNNs peuvent utiliser leur état interne (mémoire) pour traiter des séquences d'entrées de longueur variable [22] [23] [24]. Cela les rend applicables à des tâches telles que la reconnaissance d'écriture manuscrite ou la reconnaissance vocale [25] [26]. La figure II.13 présente l'architecture générale des RNNs.

Le côté gauche de la figure II.13 montre un RNN, tandis que le côté droit montre un RNN déroulé (ou déplié) dans un réseau complet. Par "déroulement", nous entendons que nous écrivons le réseau pour la séquence complète. Par exemple, si la séquence qui nous intéresse est une phrase de 3 mots, le réseau serait déroulé en un réseau de neurones à 3 couches, une couche pour chaque mot.

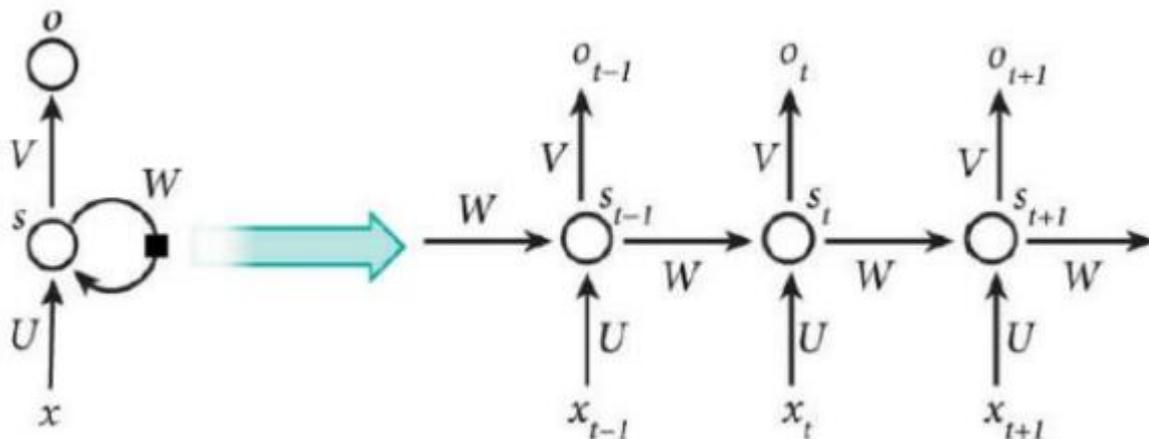


Figure II.13 : Architecture d'un réseau RNN.

II.5.2 Réseaux de neurones convolutifs

Le réseau de neurones convolutifs (Convolutional Neural Network ou CNN) est entraîné à l'aide de mégadonnées et possède la capacité d'extraire des caractéristiques des données par des convolutions sans nécessiter une extraction manuelle de caractéristiques. Il est composé de plusieurs types de couches : une couche d'entrée, une couche de sortie et des couches cachées. Les couches cachées sont constituées de couches convolutionnelles, de couches ReLU, de couches de regroupement et de couches entièrement connectées. Le CNN est l'une des architectures de deep learning les plus populaires, utilisées pour la classification et la reconnaissance des images, des textes et des sons.

La classification est une approche d'apprentissage supervisé dans laquelle le programme informatique tire des informations des données d'entrée, puis utilise cet apprentissage pour classer les nouvelles données d'observation. La classification d'image consiste à attribuer une ou plusieurs étiquettes à une image en fonction d'une catégorie prédéfinie suivant un algorithme qui détermine à quelle catégorie appartient l'image. La figure II.14 présente l'architecture générale des CNNs.

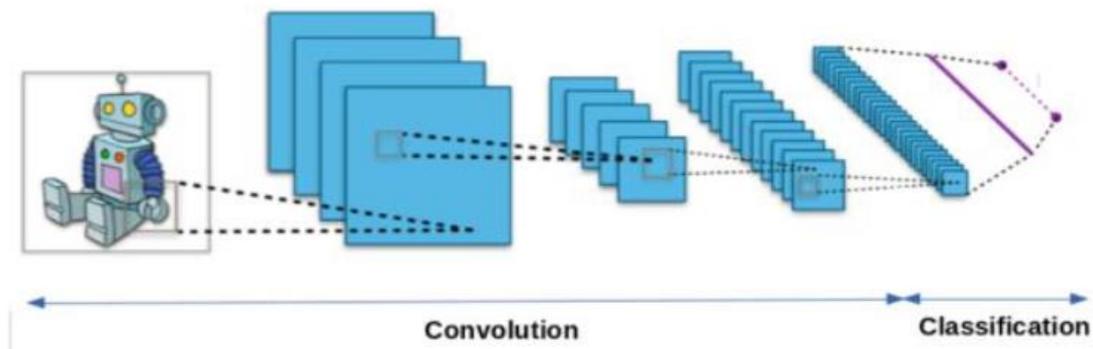


Figure II.14: Réseaux de neurones convolutifs.

II.6 Détails sur les CNNs

Les CNNs (aussi appelés ConvNets) sont actuellement les réseaux profonds les plus efficaces pour la classification des données d'images. Leurs architectures à plusieurs couches sont inspirées de la biologie. À travers ces réseaux, les caractéristiques invariantes sont apprises de manière hiérarchique et automatique. Ces réseaux permettent de reconnaître et de combiner ces caractéristiques pour apprendre des modèles plus complexes. L'architecture des CNNs comprend de nombreuses couches, comme illustré dans la figure II.15, allant de la couche d'entrée à la couche de sortie, en passant par de nombreuses couches nécessaires et importantes qui peuvent être répétées. Chacune de ces couche joue un rôle dans la réussite de la fonction des CNN.

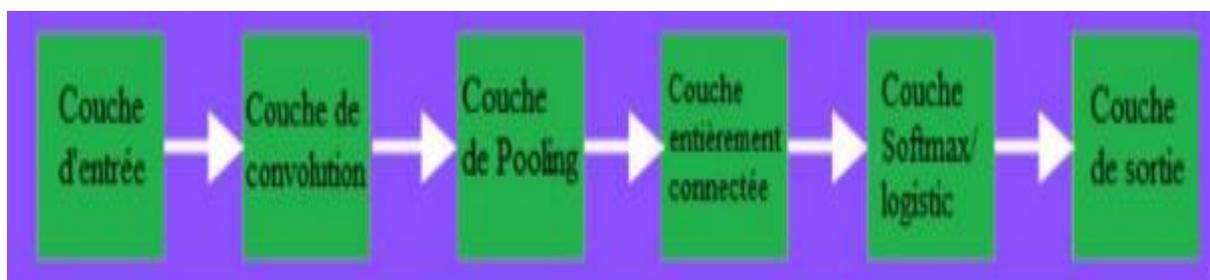


Figure II.15 : Différentes couches des CNNs.

II.6.1 Couche d'entrée

Cette couche est l'entrée du réseau CNN, que ce soit pour du texte, de l'audio ou des images. Dans un réseau de neurones traitant des images, il s'agit généralement de la matrice de pixels de l'image. Cette matrice est généralement représentée par trois dimensions : la longueur, la largeur et la profondeur (le nombre de couleurs).

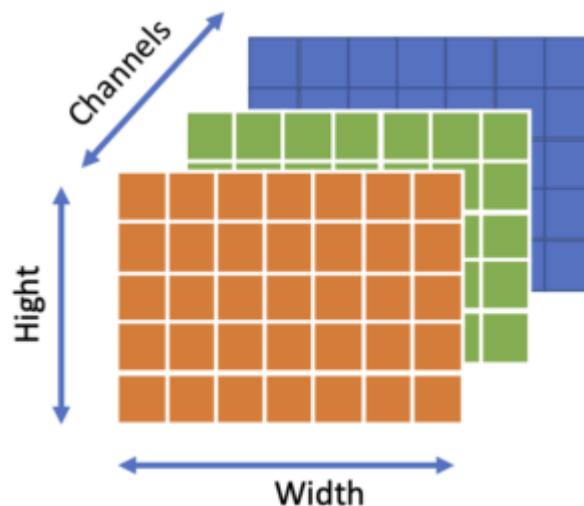


Figure II.16 : Dimensions d'une image.

II.6.2 Couche de convolution

C'est la couche la plus importante et le cœur des éléments constitutifs du réseau convolutif, et c'est aussi elle qui effectue tous les calculs lourds, car les caractéristiques de l'image sont extraites dans cette couche. Cette couche effectue une opération de convolution sur les données d'entrée.

La convolution est appliquée aux données d'entrée à l'aide d'un filtre de convolution pour produire un vecteur des caractéristiques. Les figures II.17, II.18 et II.19 présentent un exemple de l'opération de convolution.

Sur le côté gauche de la figure II.19 se trouve l'entrée de la couche de convolution, par exemple l'image d'entrée. Et à droite se trouve le filtre de convolution, également appelé noyau ou kernel. C'est ce qu'on appelle une convolution 3x3 en raison de la forme du filtre. L'opération de convolution est effectuée plusieurs fois en déplaçant le filtre sur toute la matrice ou l'image d'entrée, en multipliant la matrice avec le filtre et en additionnant le résultat. Ce processus est répété jusqu'à couvrir toutes les parties de l'image. Les convolutions produisent plusieurs matrices de caractéristiques.

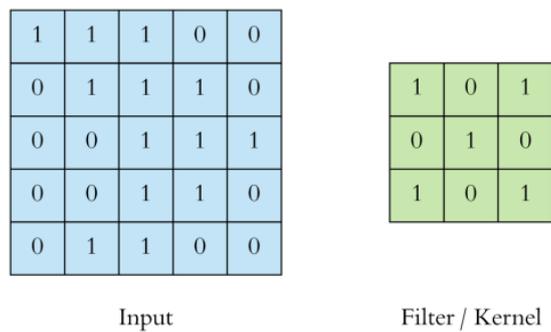


Figure II.17 : Matrice d'entrée avec le filtre de convolution.

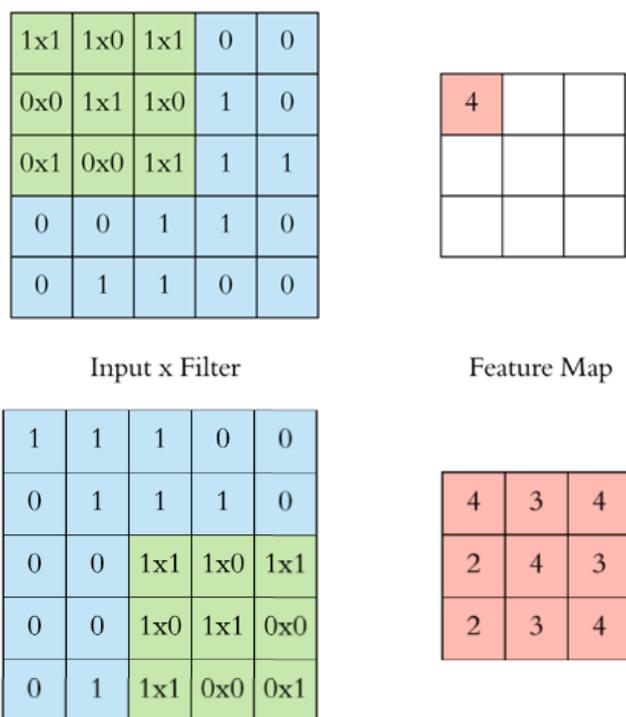


Figure II.18 : Etapes de la convolution

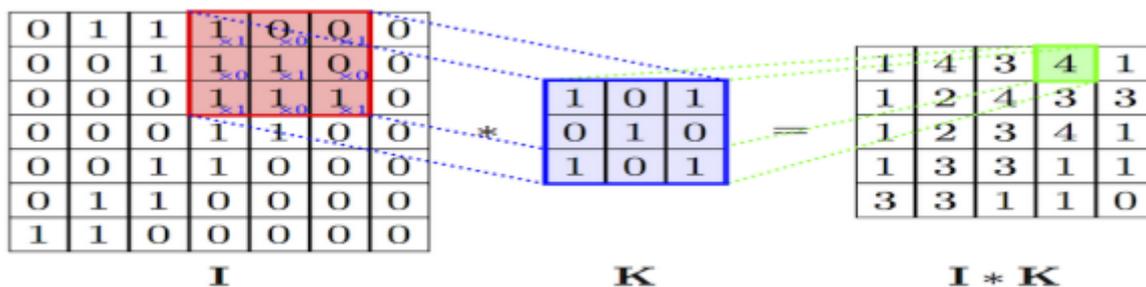


Figure II.19 : Principe du filtre de convolution [27].

II.6.3 Couche de pooling

Cette couche est utilisée pour réduire la taille de l'image d'entrée après la convolution en effectuant une opération de pooling. Son rôle est également de réduire le nombre de paramètres et de calculs dans le réseau, et donc de contrôler le sur-apprentissage (overfitting).

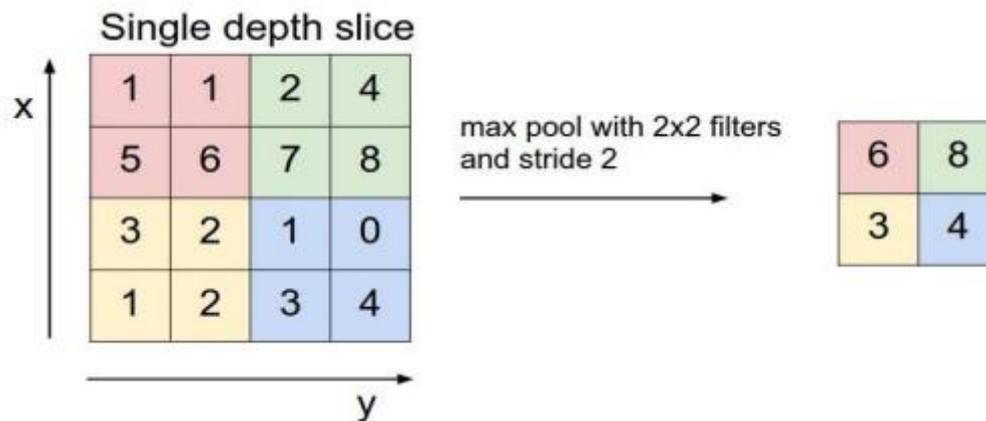


Figure II.20 : Principe du Pooling [28].

L'opération de pooling est une technique utilisée les CNN pour réduire la dimensionnalité des cartes de caractéristiques générées par les couches de convolution. Elle consiste à remplacer plusieurs valeurs dans une région (fenêtre de voisinage) par une seule valeur représentative, généralement basée sur une opération statistique comme la valeur maximale (max pooling) ou la moyenne (average pooling). Cela permet de réduire le nombre de paramètres et de calculs dans le réseau, tout en préservant les caractéristiques les plus importantes de l'image.

La figure II.20 illustre un exemple de maxpooling, où chaque groupe de quatre pixels situés dans une fenêtre de voisinage de 2x2 est remplacé par leur valeur maximale.

II.6.4 Couche d'activation

Cette couche suit la couche de convolution et applique une fonction mathématique appelée fonction d'activation sur les signaux de sortie. Cette fonction, également connue sous le nom de "fonction d'activation non saturante", renforce les propriétés de non-linéarité de la fonction de décision et de l'ensemble du réseau sans affecter les champs récepteurs de la couche de convolution.

Il existe plusieurs types de fonctions d'activation :

- ✓ La fonction tangente hyperbolique : $f(x) = \tanh(x)$.
- ✓ La fonction tangente hyperbolique saturante : $f(x) = |\tanh(x)|$.

- ✓ La fonction sigmoïde.
- ✓ La fonction Rectified Linear Unit : $f(x) = \max(0, x)$.

ReLU est actuellement la fonction d'activation la plus utilisée par rapport au sigmoïde et au Tanh, car elle élimine complètement certains inconvénients, notamment le problème de fuite de gradient. Cela rend ReLU plus avantageuse que les autres fonctions d'activation.

II.6.5 Couche Flatten

La couche "flatten" (ou "aplatissement") dans un réseau CNN est une couche qui transforme les données multidimensionnelles en un vecteur unidimensionnel. Elle est généralement utilisée pour préparer les données avant de les passer à une couche entièrement connectée pour la classification. Cette opération est réalisée en prenant toutes les dimensions des données d'entrée et en les combinant dans un seul vecteur, ce qui permet au réseau de neurones de les traiter comme une séquence linéaire d'entrées.

II.6.6 Couche complètement connectée

La couche complètement connectée (Fully connected layer ou FC), également appelée couche dense, est une couche de neurones dans un réseau de neurones artificiels où chaque neurone est connecté à tous les neurones de la couche précédente, et tous les neurones de cette couche contribuent aux sorties de chaque neurone de la couche suivante. Cette couche est utilisée pour combiner les caractéristiques extraites des données dans les couches précédentes et effectuer une classification ou une prédiction finale [29]. Cette couche souvent utilisée dans les CNN après les couches d'extraction de caractéristiques pour effectuer la classification finale.

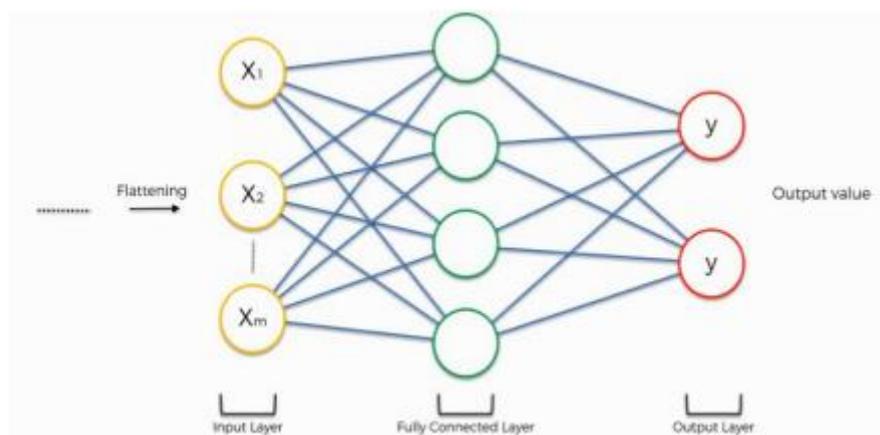


Figure II.21 : Architecture de la couche complètement connectée.

II.6.7 Couche de sortie (output layer)

La couche de sortie transforme la sortie en un nombre de classes souhaité par le réseau. Elle contient une étiquette représentant le résultat attendu, généralement sous forme numérique codée, comme illustré dans la figure II.22.

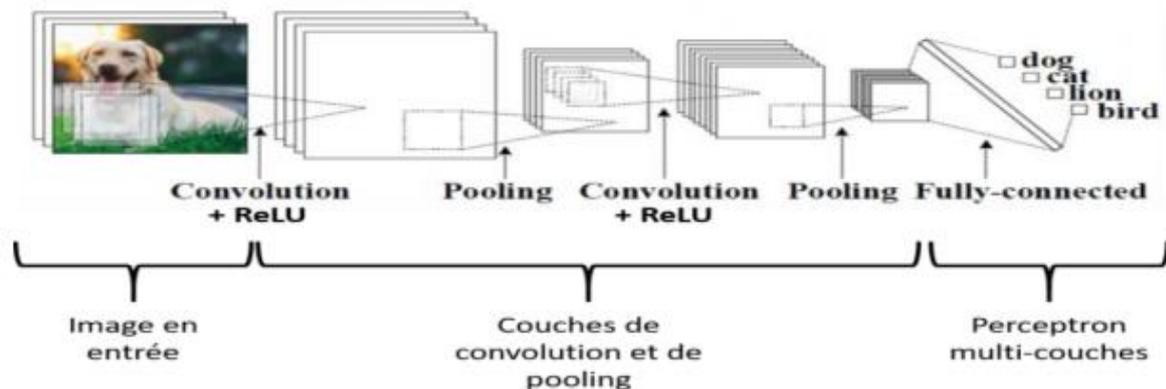


Figure II.22: Exemple montrant l'étiquette codée de la couche de sortie CNN [29].

La fonction softmax est une généralisation de la fonction logistique à plusieurs dimensions. La logistique est utilisée pour la classification binaire, tandis que Softmax est utilisée pour la classification multi-classe. La fonction softmax est utilisée dans la régression logistique multinomiale et est souvent utilisée comme dernière fonction d'activation d'un réseau de neurones pour normaliser la sortie d'un réseau vers une distribution de probabilité sur les classes de sortie prédites [30]. La fonction softmax prend en entrée un vecteur composé de k nombres réels et le normalise en une distribution de probabilité constituée de k probabilités proportionnelles aux exponentielles des nombres d'entrées. Autrement dit, avant l'application du softmax, certaines composantes vectorielles pourraient être négatives ou supérieures à un, et leur somme peut ne pas être égale à 1. Cependant, après l'application du softmax, chaque composante sera dans l'intervalle $[0,1]$, et la somme des composantes sera égale à 1, ce qui permet de les interpréter comme des probabilités. De plus, les composantes d'entrée les plus grandes correspondront à des probabilités plus grandes [30].

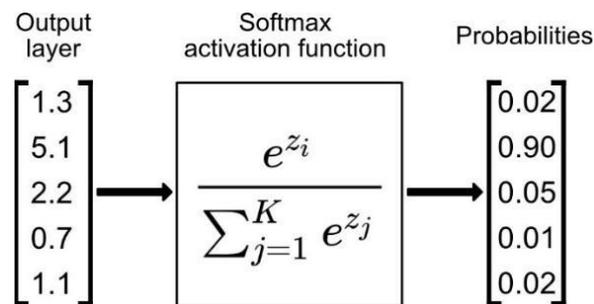


Figure II.23 : Fonction softmax [30].

II.6.8 Autres outils des CNNs

II.6.8.1 Fonction d'erreur

La fonction d'erreur (fonction de perte ou fonction de coût, en anglais loss function) spécifie comment l'entraînement du réseau pénalise l'écart entre le signal prévu et le signal réel. Elle calcule l'erreur entre la sortie désirée ou connue et la sortie produite par le réseau. Diverses fonctions d'erreur adaptées à différentes tâches peuvent être utilisées.

Lorsque la fonction Softmax est utilisée pour prédire une seule classe parmi K classes mutuellement exclusives, la fonction d'erreur par entropie croisée sigmoïde est utilisée pour prédire dans ce cas K valeurs de probabilité indépendantes dans l'intervalle $[0,1]$. La fonction d'erreur euclidienne est généralement utilisée pour régresser vers des valeurs réelles [31]. Dans le cas d'une classification en deux classes, la fonction d'erreur la plus utilisée est l'entropie croisée binaire (en anglais binary cross entropy). Cette fonction est donnée comme suit :

$$\text{fonction d'erreur} = - \sum_{i=1}^{C=2} t_i \log(s_i) = t_1 \log(s_1) - (1 - t_1) \log(1 - s_1) \quad (\text{II.5})$$

Où C représente les classes, s_i est la valeur de probabilité prédite pour la classe i , et t est la vraie probabilité pour cette classe.

II.6.8.2 Dropout

Le problème de surapprentissage (overfitting) survient généralement lorsque certains neurones deviennent trop interdépendants au fur et à mesure de l'apprentissage. Le dropout résout ce problème en supprimant aléatoirement certaines connexions entre les neurones pendant l'apprentissage, en spécifiant un paramètre crucial à chaque fois, le "taux".

Le paramètre taux est une valeur comprise entre 0 et 1, représentant la probabilité de suppression d'une connexion entre neurones. En pratique, il est généralement choisi entre 0.2 et 0.75.

II.6.8.3 Normalisation par lots

La normalisation par lots (batch normalization) est une technique qui améliore la vitesse et les performances finales d'un réseau de neurones artificiel. Elle normalise et met à l'échelle les données à l'entrée du réseau de neurones en ajustant toutes les valeurs de la couche d'entrée. Cela permet de régulariser le modèle neuronal et d'éviter que certaines données très élevées dominent les autres. De plus, cela permet de tirer parti des données les plus petites qui peuvent être très importantes pour le fonctionnement du réseau neuronal. La normalisation par lots peut également être utilisée entre les différentes couches d'un réseau de neurones. Cela permet de régulariser les activations des neurones à chaque couche, aidant ainsi à maintenir une stabilité du gradient tout au long de l'entraînement.

II.6.8.4 Arrêt anticipé

L'arrêt anticipé (early stopping) est une méthode de régularisation qui consiste à interrompre l'entraînement d'un modèle d'apprentissage lorsque la perte sur un ensemble de données de validation commence à augmenter et que les performances de généralisation se dégradent.

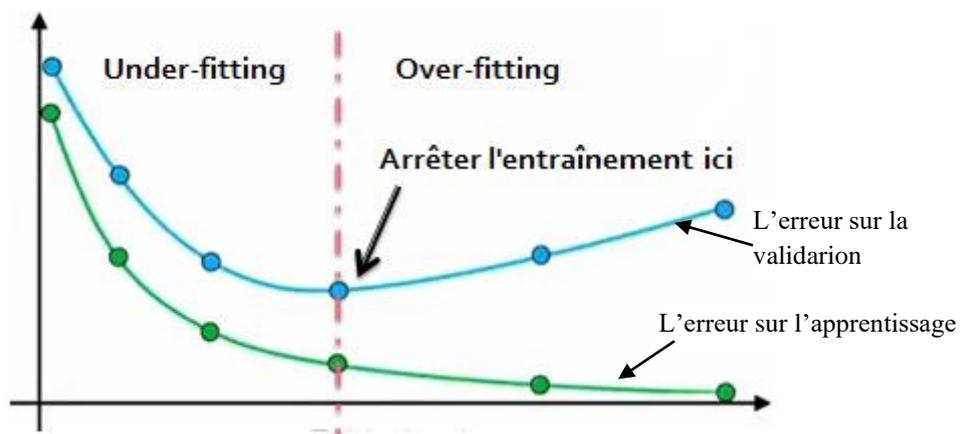


Figure II.24 : Utilisation de l'arrêt anticipé dans la phase d'entraînement d'un modèle.

II.6.8.5 Augmentation des données

L'augmentation des données est une technique utilisée pour augmenter la quantité de données en ajoutant des copies légèrement modifiées de données déjà existantes ou en créant de nouvelles données synthétiques à partir de données existantes. Elle agit comme un régulateur et aide à réduire le surapprentissage lors de l'entraînement d'un modèle d'apprentissage

automatique. Cette technique est étroitement liée au suréchantillonnage dans l'analyse des données.

II.6.8.6 Apprentissage par transfert

L'apprentissage par transfert (Transfer Learning) désigne l'ensemble des méthodes permettant de transférer les connaissances acquises lors de la résolution d'un problème donné pour traiter un autre problème. Cette approche a connu un grand succès avec l'essor du Deep Learning. En effet, les modèles utilisés dans ce domaine nécessitent souvent des temps de calcul élevés et des ressources importantes. En utilisant des modèles pré-entraînés comme point de départ, l'apprentissage par transfert permet de développer rapidement des modèles performants et de résoudre efficacement des problèmes complexes.

II.6.8.7 Optimisation

a) Méthode du gradient stochastique

La méthode du gradient stochastique (Stochastic Gradient Descent ou SGD) et ses variantes sont probablement les algorithmes d'optimisation les plus couramment utilisés pour l'apprentissage automatique en général, et en particulier pour l'apprentissage profond. Pour obtenir une estimation objective du gradient, on prend une moyenne du gradient sur un mini-lot d'échantillons prélevés dans la distribution génératrice de données. L'algorithme SGD montre comment suivre cette estimation de descente de gradient. Le paramètre clé de l'algorithme SGD est le taux d'apprentissage. Le SGD utilise un taux d'apprentissage constant, mais dans la pratique, il est nécessaire de réduire progressivement le taux d'apprentissage au fil du temps. À titre de comparaison, le véritable gradient de la fonction de coût total devient petit, puis atteint 0 lorsque nous approchons et atteignons le minimum à l'aide d'un gradient par lots.

b) Méthode RMSprop

La méthode RMSprop a été développée par le professeur Geoffrey Hinton dans ses cours sur les réseaux neuronaux. Au lieu de laisser tous les gradients s'accumuler pour le Momentum, RMSprop n'accumule les gradients que dans une fenêtre fixe. Cette méthode tente également de réduire les oscillations, mais d'une manière différente du Momentum. RMSprop évite également de devoir ajuster manuellement le taux d'apprentissage, en le faisant automatiquement. De plus, RMSprop choisit un taux d'apprentissage différent pour chaque paramètre. Chaque mise à jour dans RMSprop est effectuée selon des équations spécifiques et séparément pour chaque paramètre.

c) Méthode Adam

Adam, est l'abréviation de "Adaptive Moment Estimation", c'est la méthode d'optimisation la plus utilisée dans le deep learning. Elle propose une autre manière d'utiliser les gradients passés pour calculer les gradients actuels. Adam utilise également le concept de moment adaptatif en ajoutant des fractions de gradients précédents au gradient actuel. Cette méthode d'optimisation est devenue assez répandue et est généralement acceptée pour l'entraînement des réseaux neuronaux. Bien qu'il soit facile de se perdre dans la complexité de certains de ces nouveaux optimiseurs, il suffit de se rappeler qu'ils ont tous le même objectif : minimiser la fonction de perte. Adam est généralement considéré comme assez robuste dans la sélection d'hyperparamètres, bien que le taux d'apprentissage doive parfois être ajusté par rapport à la valeur par défaut suggérée.

II.7 Travaux Connexes sur la Détection du Cancer de la Peau en utilisant le Deep Learning

La détection du cancer de la peau à l'aide du deep learning a été explorée par plusieurs études, chacune contribuant de manière significative à ce domaine. Voici une synthèse des travaux similaires.

1. **Skin Cancer Malignancy Classification with Transfer Learning** [32]

Cette étude se concentre sur deux aspects principaux :

- **Quantification de la gravité des lésions cutanées** : L'évaluation de la sévérité des lésions a abouti à un score F1 de 87% et une spécificité de 78%.
- **Classification de la malignité des lésions cutanées** : En utilisant l'apprentissage par transfert, les images redimensionnées et prétraitées ont permis d'obtenir un score F1 de 95% pour les cas de malignité.

2. **Traitement d'images comme outil de diagnostic du cancer de la peau** [33]

Cette recherche développe une chaîne de traitement d'images dermoscopiques pour classifier les mélanomes comme bénins ou malins. Utilisant une méthode de détection de contours basée sur l'algorithme d'optimisation des colonies de fourmis, les tests sur les bases de données DermIS et DermQuest ont montré :

- Un taux de classification de 93.60% avec des réseaux de neurones.
- Un taux de 84.27% en utilisant les K-plus proches voisins.

3. **Skin Cancer Classification Using Convolutional Neural Networks: Systematic Review** [34]

Ce travail compile et analyse 13 articles utilisant les réseaux de neurones convolutifs (CNN) pour la classification des lésions cutanées. Il introduit des mesures statistiques pour évaluer différents classificateurs et présente des méthodes utilisant les CNN comme extracteurs de fonctionnalités.

4. **Développement d'une application sous Android Pour la détection des tumeurs de la peau [35]**

Une application mobile, "DERM-APP", a été développée pour capturer des photos de tumeurs cutanées avec une caméra de smartphone en utilisant la bibliothèque OpenCV. Les images sont ensuite stockées dans une base de données locale, facilitant l'analyse et la détection des tumeurs de la peau.

5. **Skin Cancer Detection: Applying a Deep Learning Based Model Driven Architecture in the Cloud for Classifying Dermal Cell Images [36]**

Ce travail propose un outil permettant aux non-programmeurs de développer des modèles complexes de deep learning. Il met en avant des options de flexibilité dans la conception de classificateurs d'apprentissage profond en suivant des procédures générales et des modèles de boucle dans le développement de ces modèles.

Ces études montrent la diversité et l'innovation dans l'utilisation du deep learning pour la détection du cancer de la peau, en utilisant des approches allant des applications mobiles aux algorithmes d'optimisation avancés et aux architectures basées sur le cloud.

II.8 Conclusion

Le deep learning est un vaste domaine qui se développe tous les jours et qui ouvre la voie à l'exploration et à la réponse à de nombreux besoins et problèmes humains, il va au-delà des différentes méthodes d'apprentissage automatique en termes de performances et est largement utilisé pour une variété de tâches différentes. Le deep learning a amélioré la précision par rapport à d'autres approches de tâches telles que la traduction de la langue et la reconnaissance d'images. Il est actuellement une technique à la mode pour la recherche dans plusieurs domaines en particulier dans le domaine médical pour la détection des pathologies ou la classification des maladies telles que le cancer de la peau. Nous avons présenté dans ce chapitre le principe de base du deep learning et ses différents outils, ces notions de base seront très utiles pour comprendre notre approche de détection du cancer de la peau qui sera présentée et testée dans le prochain chapitre.

Chapitre 3

Expériences et résultats

III.1 Introduction

Après avoir présenté la théorie de l'apprentissage profond dans le chapitre précédent, ce chapitre sera consacré à la mise en œuvre d'un système basé sur l'apprentissage profond pour la détection du cancer de la peau. Pour cela, nous allons utiliser une base d'images du cancer de la peau contenant deux classes : la première classe représente un cancer positif et l'autre un cancer négatif. Nous allons également présenter notre modèle de réseau de neurones convolutifs (CNN) développé pour la classification de cette maladie. Les résultats des tests de notre architecture seront aussi présentés et détaillés dans ce chapitre.

III.2 Environnement du travail

Dans cette section, nous présenterons le matériel et le logiciel utilisés dans notre projet.

III.2.1 Environnement matériel

Pour la mise en œuvre de ce projet, nous avons utilisé un ensemble de matériel avec les caractéristiques suivantes :

- ✓ Ordinateur portable Lenovo
- ✓ Processeur : Intel(R) Celeron(R) CPU N3060 @ 1.60GHz
- ✓ Mémoire (RAM) : 4Go
- ✓ Système d'exploitation : Microsoft Windows 10 (64 bits).

III.2.2 Langage de programmation Python

Python a été développé à l'institut néerlandais de mathématiques et d'informatique (CWI) à Amsterdam par Guido van Rossum à la fin des années 1980, et sa première annonce remonte à 1991. Le noyau du langage est écrit en langage C. Ross a appelé son langage "Python" pour exprimer son admiration pour un célèbre groupe de sketches britannique qui s'appelait Monty Python. [37]

Python est un langage de programmation de haut niveau conçu pour être facile à lire et à implémenter. Il est open source, ce qui signifie qu'il est gratuit, même pour des applications commerciales. Python peut fonctionner sur les systèmes Mac, Windows et Unix. [37]



Figure III.1 : Logo Python.

III.2.3 Google Colab

Google Colab ou Colaboratory est un service cloud, offert par Google (gratuit), basé sur Jupyter Notebook et destiné à la formation et à la recherche dans l'apprentissage automatique. Cette plateforme permet d'entraîner des modèles de Machine Learning directement dans le cloud sans donc avoir besoin d'installer quoi que ce soit sur notre ordinateur à l'exception d'un navigateur [38].

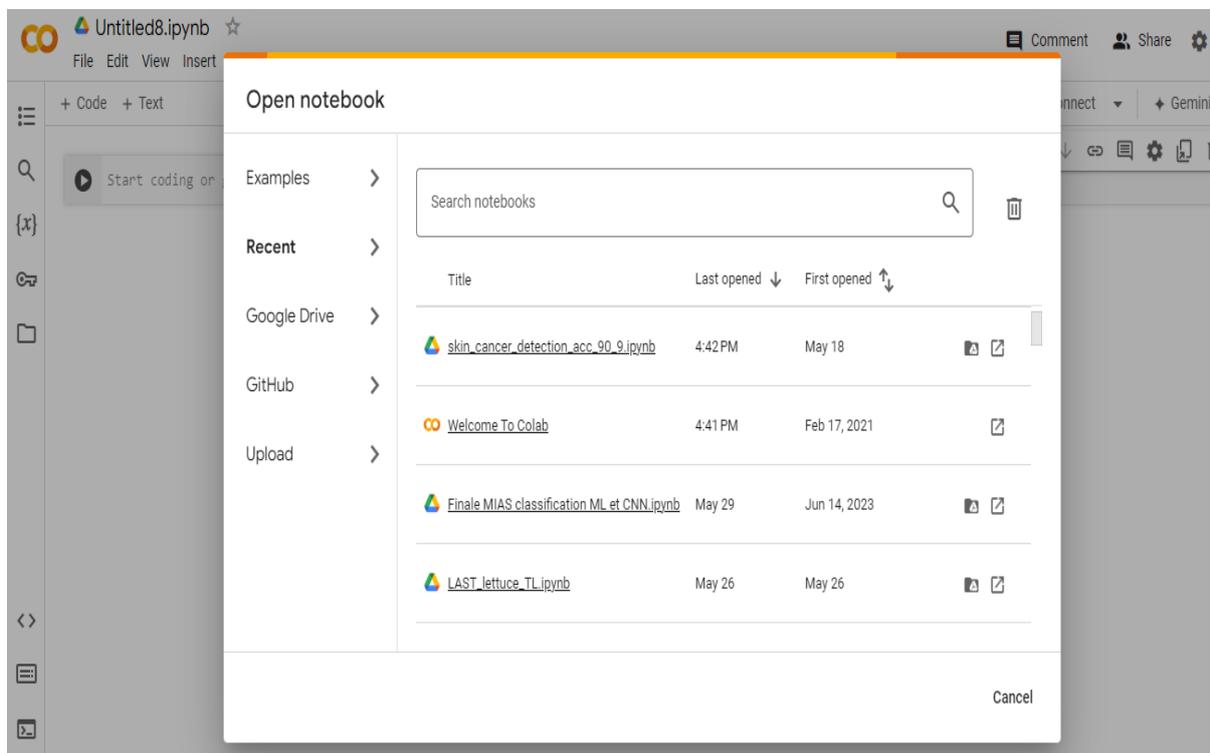


Figure III.2 : Interface de google Colab.

III.2.4 Navigateur Anaconda

Le Navigateur Anaconda est une interface graphique (GUI) incluse dans la distribution Anaconda et qui permet aux utilisateurs de lancer des applications, mais aussi de gérer les librairies conda. Le Navigateur peut également accéder à des librairies présentes sur le Cloud Anaconda ou dans un Repository Anaconda local, afin de les installer dans un

environnement, les exécuter et les mettre à jour. Il est disponible pour Windows, macOS et Linux [39].

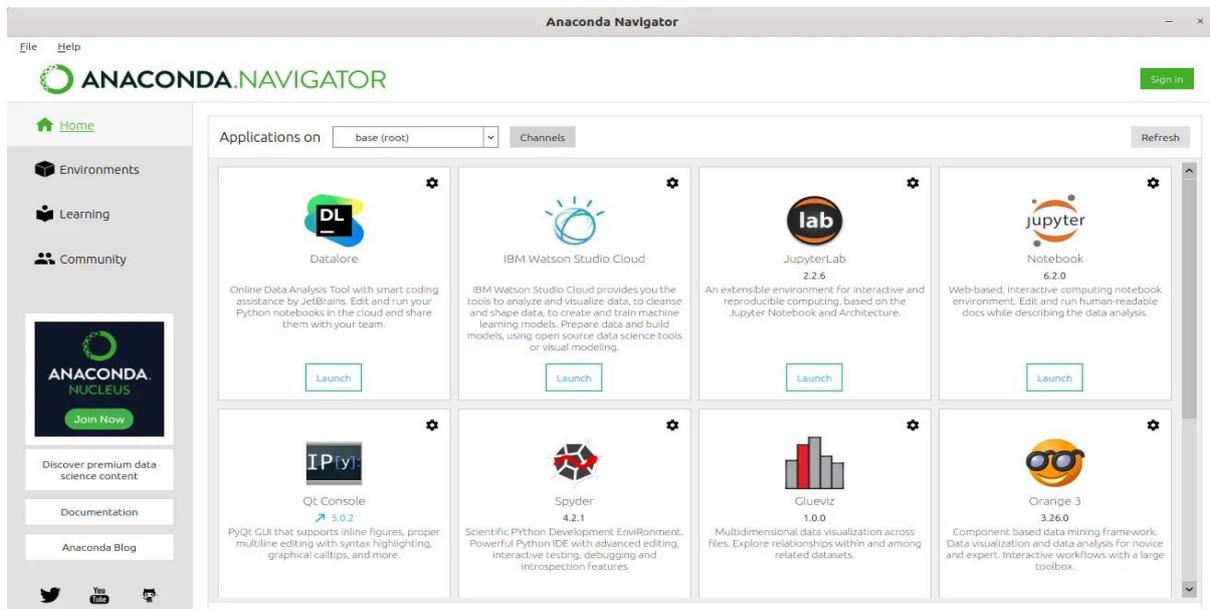


Figure III.3 : Navigateur Anaconda.

III.2.5 Jupyter Notebook

Jupyter Notebook est une application web open source qui vous permet de créer et partager des documents contenant du code en direct, des équations, des visualisations et du texte narratif. Les utilisations comprennent : le nettoyage et la transformation des données, la simulation numérique, la modélisation statistique, la visualisation de données, l'apprentissage automatique et bien plus encore [40].

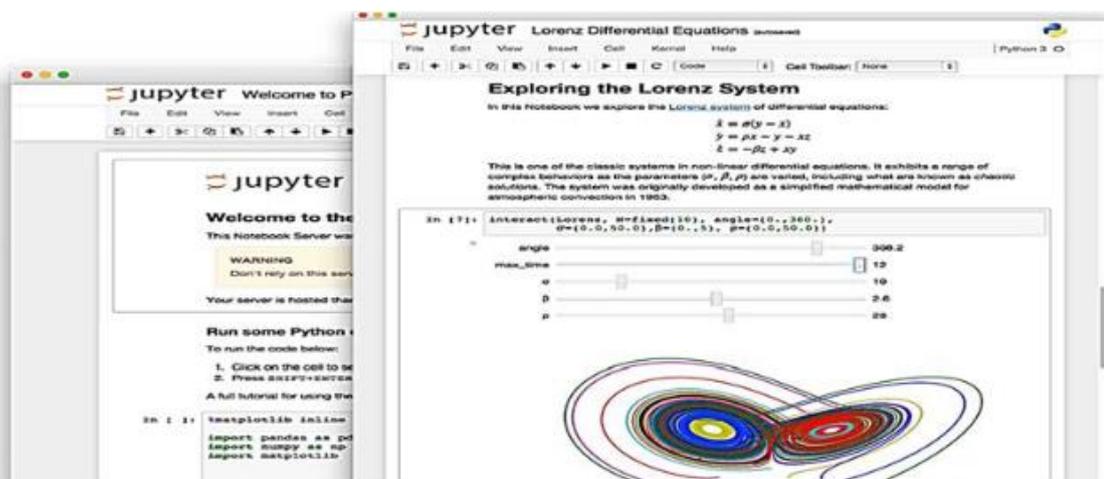


Figure III.4: Jupyter notebook.

III.2.6 Keras

C'est une API de haut niveau permettant de créer et de former des modèles d'apprentissage en profondeur, capable de s'exécuter sur Tensorflow, il est utilisé pour le prototypage rapide, la recherche avancée et la production. Les modèles Keras sont fabriqués en reliant des blocs de construction configurables ensemble, donc Keras nous permet de créer de nouvelles couches, des fonctions et développer des modèles à la pointe de la technologie avec peu de restrictions en quelques lignes de code seulement [41].

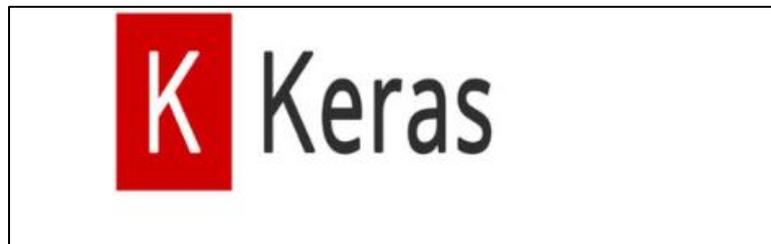


Figure III.5: Logo Keras.

III.2.7 TensorFlow

TensorFlow est un outil open source d'apprentissage automatique développé par Google. Le code source a été ouvert le 9 novembre 2015 par Google et publié sous licence Apache. Il est fondé sur l'infrastructure DistBelief, initiée par Google en 2011, et est doté d'une interface pour Python, Julia et R2. TensorFlow est l'un des outils les plus utilisés en IA dans le domaine de l'apprentissage machine.



Figure III.6: Logo TensorFlow.

III.2.8 OpenCV

OpenCV (Open Source Computer Vision Library) est une bibliothèque logicielle open source dédiée à la vision par ordinateur et à l'apprentissage automatique. OpenCV a été créée pour

fournir une infrastructure commune aux applications de vision par ordinateur et pour accélérer l'utilisation de la perception machine dans les produits commerciaux. Étant sous licence BSD, OpenCV permet aux entreprises d'utiliser et de modifier facilement le code.

La bibliothèque contient plus de 2500 algorithmes optimisés, comprenant un ensemble complet d'algorithmes de vision par ordinateur et d'apprentissage automatique, allant des classiques aux plus avancés. Ces algorithmes peuvent être utilisés pour détecter et reconnaître des visages, identifier des objets, classifier des actions humaines dans des vidéos, suivre les mouvements de caméra, suivre des objets en mouvement, extraire des modèles 3D d'objets, produire des nuages de points 3D à partir de caméras stéréo, assembler des images pour produire une image haute résolution d'une scène entière, trouver des images similaires dans une base de données d'images, supprimer les yeux rouges des photos prises avec un flash, suivre les mouvements des yeux, reconnaître des paysages et établir des marqueurs pour les superposer avec la réalité augmentée, etc. OpenCV compte plus de 47 000 utilisateurs dans sa communauté et un nombre estimé de téléchargements dépassant les 18 millions. La bibliothèque est largement utilisée par des entreprises, des groupes de recherche et des organismes gouvernementaux.

III.2.9 Numpy

La bibliothèque Numpy (Numerical Python) est une bibliothèque populaire en Python qui fournit des structures de données et des fonctions pour manipuler efficacement des tableaux multidimensionnels. Il est largement utilisé dans les domaines scientifiques et numériques tels que le calcul mathématique, le fonctionnement des tableaux, l'algèbre linéaire, le traitement du signal et la simulation.

III.2.10 Pandas

Pandas est une bibliothèque open source de manipulation et d'analyse de données pour le langage de programmation Python. Elle offre des structures de données flexibles et expressives, principalement les DataFrames et les Series, qui facilitent la manipulation de données tabulaires et de séries temporelles. Pandas est particulièrement utile pour nettoyer, transformer et analyser des données, grâce à ses fonctionnalités puissantes pour la sélection, le filtrage, l'agrégation et la visualisation des données.

III.3 Dataset utilisée

Dans notre étude, nous utilisons la dataset « Skin Cancer dataset » de l'ISIC (The International Skin Imaging Collaboration) (<https://www.isic-archive.com/>). L'ISIC est une organisation internationale dont l'objectif principal est d'améliorer le diagnostic du cancer de la peau en promouvant des standards dans l'imagerie cutanée, en rassemblant et en partageant des images dermatologiques, et en engageant des cliniciens et des chercheurs en vision par ordinateur. Cette dataset contient 3600 images de taille 224x224, parmi lesquelles 1800 représentent un cancer de la peau et 1800 représentent des cas non cancéreux.



Figure III.7 Quelques images de notre dataset.

III.4 Prétraitement et augmentation des données

Le prétraitement consiste à appliquer des modifications aux images de notre base de données afin de les améliorer. L'augmentation des données consiste à accroître le nombre d'images en effectuant un certain nombre de transformations aléatoires, de sorte que notre modèle ne voit jamais deux fois exactement la même image. Cela permet d'éviter le sur-apprentissage et aide le modèle à mieux se généraliser. Dans Keras, cela peut être réalisé via la classe `keras.preprocessing.image.ImageDataGenerator`.

L'ImageDataGenerator est un utilitaire fourni par des bibliothèques comme TensorFlow et Keras, qui permet d'effectuer une augmentation des données en temps réel pendant le processus d'entraînement. Au lieu de stocker les images augmentées séparément, ImageDataGenerator applique des transformations aléatoires aux images juste avant de les fournir au modèle pour l'entraînement. ImageDataGenerator permet de configurer les transformations aléatoires et les opérations de normalisation à effectuer sur nos données pendant l'entraînement, et d'instancier des générateurs de batchs d'images augmentées (et leurs étiquettes).

```
[13] train_dir = '/content/drive/MyDrive/dataset/train'
     test_dir = '/content/drive/MyDrive/dataset/test'

     try:
         # Obtenir les données divisées
         train_df, valid_df, test_df = split_data(train_dir, test_dir)

         # Obtenir les générateurs
         batch_size = 40
         train_gen, valid_gen, test_gen = create_gens(train_df, valid_df, test_df, batch_size)

     except:
         print('Entrée invalide')
```

Figure III.8 : Génération des deux classes d'entraînement et de test.

Le prétraitement consiste également à améliorer la qualité ou les caractéristiques d'une image avant qu'elle ne soit utilisée dans un modèle d'apprentissage automatique pour l'entraînement ou l'inférence. Ces techniques visent à améliorer les caractéristiques de l'image, à supprimer le bruit, à augmenter le contraste ou à ajuster les couleurs pour rendre l'image plus adaptée à l'analyse par le modèle. Pour notre application, nous avons utilisé l'Image Enhancement. Cette méthode applique des améliorations à l'image en utilisant trois techniques d'amélioration d'images PIL : Couleur, Contraste et Netteté. Ces améliorations visent à améliorer respectivement la couleur, le contraste et la netteté de l'image.

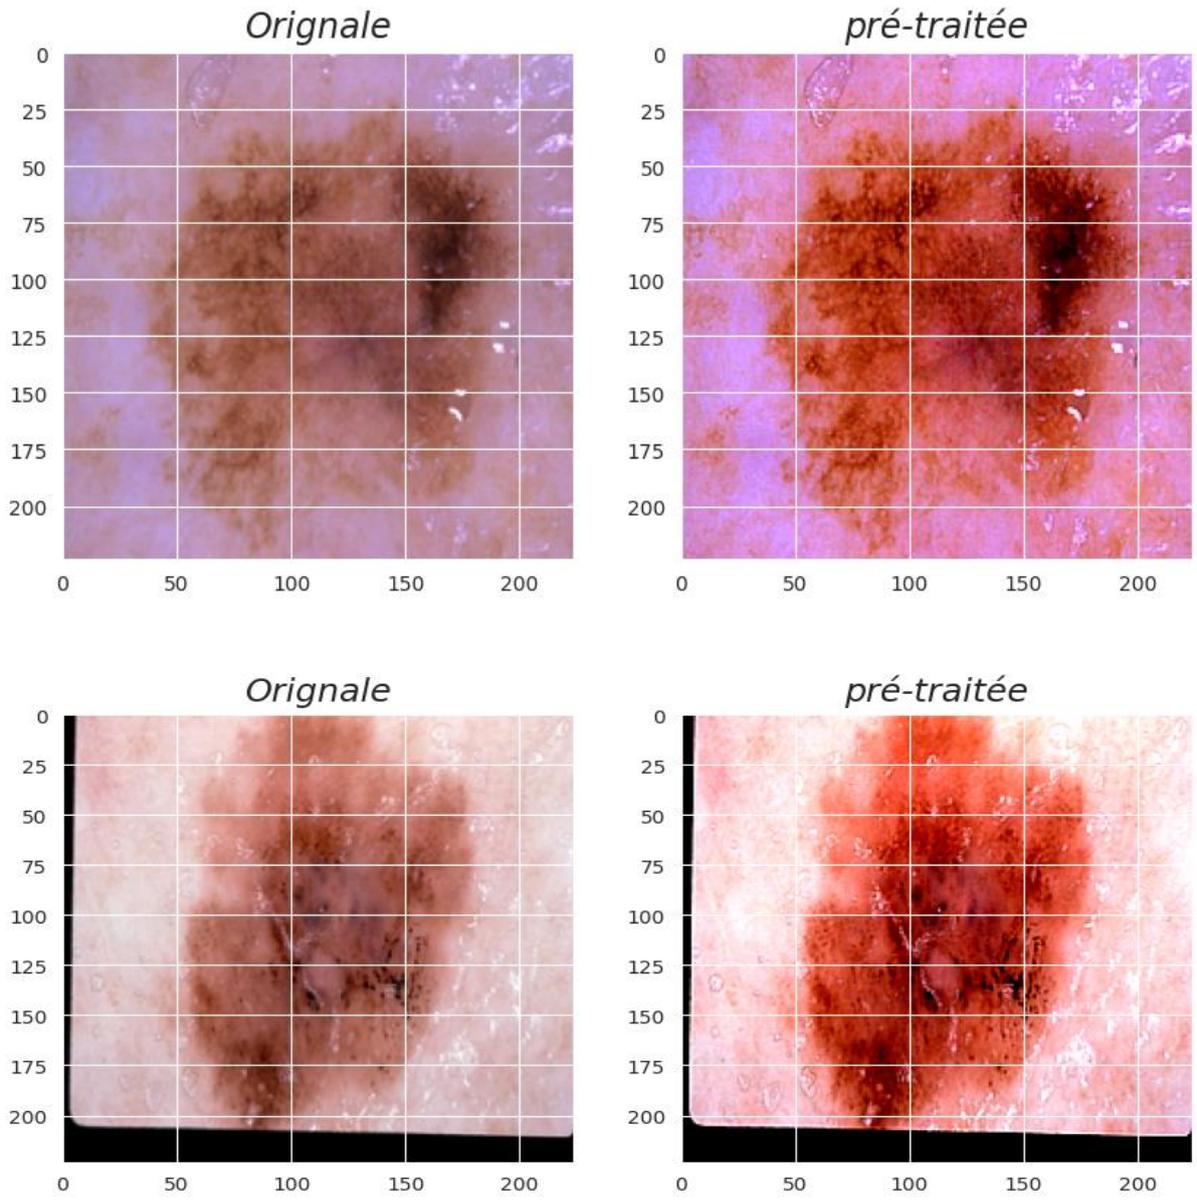


Figure III.9: Exemple de prétraitement d'images.

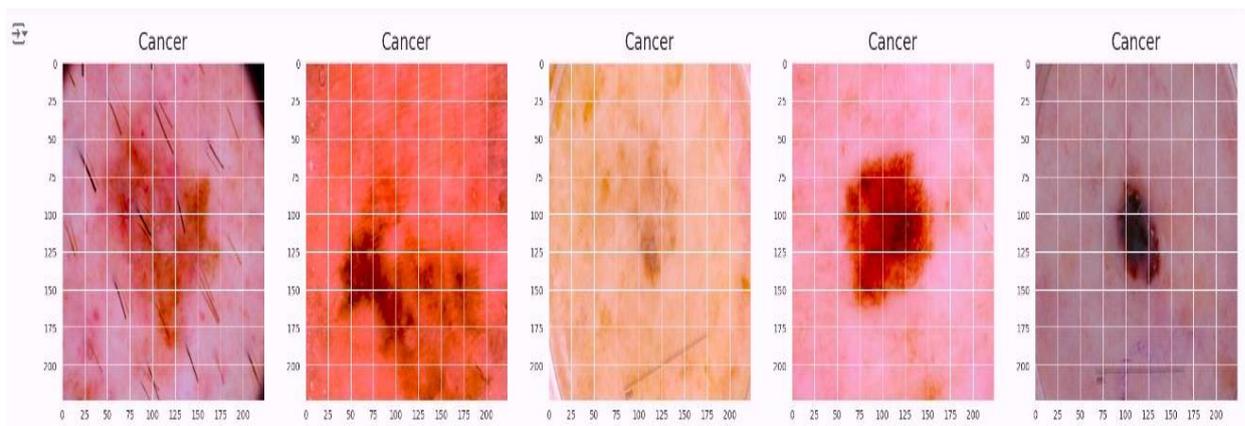


Figure III.10: Image cancéreuse prétraitée.

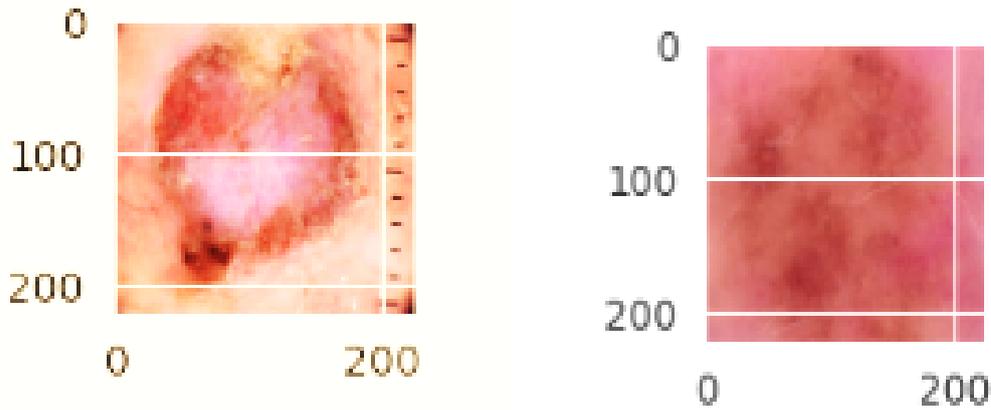


Figure III.11: Exemple de deux images améliorées : image cancéreuse à droite et image non cancéreuse à gauche.

III.5 Modèles de détection du cancer de la peau

La structure générale de nos modèles consiste en l'utilisation de plusieurs couches de convolution. Ces couches permettent de prendre les données d'origine et de créer des cartes de caractéristiques. Les couches de convolution sont suivies par plusieurs couches de pooling. Le pooling peut être vu comme une opération de sous-échantillonnage, le plus souvent sous la forme de "pooling maximal", où nous sélectionnons une région, puis prenons la valeur maximale dans cette région ; cette valeur devient alors la nouvelle valeur pour toute la région. Les couches entièrement connectées sont les dernières couches de nos modèles, dans lesquelles tous les nœuds sont "entièrement connectés". Les couches convolutionnelles ne sont pas entièrement connectées comme un réseau de neurones traditionnel. La structure générale des CNN est montrée sur la figure III.12.

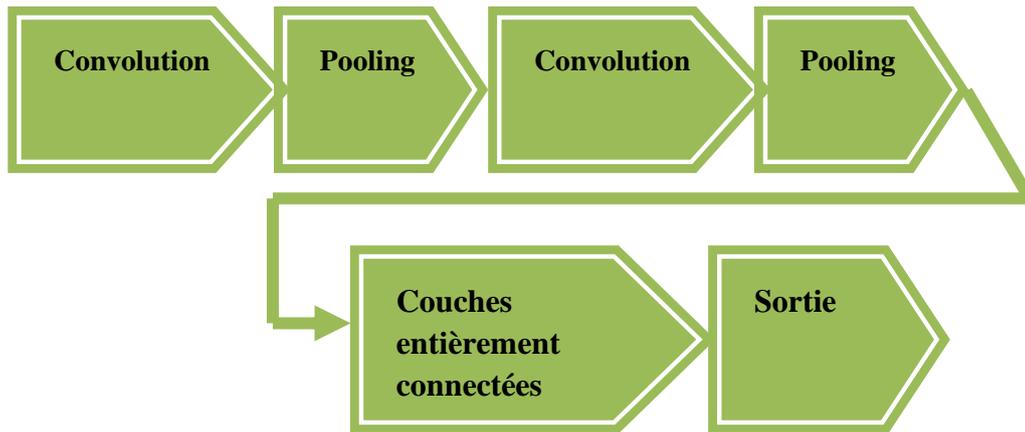


Figure III.12 : Structure de base des CNNs.

Au cours de nos expérimentations, nous avons créé trois modèles avec différentes architectures. Le modèle 1 est un modèle personnalisé, le modèle 2 exploite le transfert learning avec VGG16, et le modèle 3 utilise également le transfert learning mais avec le réseau EfficientNet. Dans ce qui suit, nous présenterons l'architecture de chacun de ces trois modèles.

III.5.1 Architecture de notre modèle 1 (modèle personnalisé)

Notre premier modèle est un modèle personnalisé. Ce modèle est composé de plusieurs blocs de convolution où chaque bloc est constitué d'une convolution suivie d'une batch normalization.

- Bloc 1 : L'image en entrée est de taille 224×224 . L'image passe d'abord par la première couche de convolution. Cette couche est composée de 32 filtres de taille 3×3 avec un padding="same". La fonction d'activation ReLU est utilisée pour forcer les neurones à retourner des valeurs positives. Après cette convolution, 32 cartes de caractéristiques (feature maps) de taille 224×224 sont créées. Cette couche de convolution est suivie par une couche de batch normalization pour maintenir la sortie moyenne proche de 0 et l'écart type de sortie proche de 1.
- Bloc 2 : Ce bloc est une répétition du bloc 1. Le résultat de ce bloc est 32 feature maps de taille 224×224 .
- Bloc 3 : Le max pooling est appliqué au bloc 2 pour réduire la taille de l'image et des paramètres, la taille de l'image devient 112×112 . La couche de max pooling est suivie d'une couche de dropout.

- Bloc 4 : Les 32 cartes de caractéristiques obtenues du bloc 3 sont données comme entrée à la deuxième couche de convolution, composée de 64 filtres utilisant la fonction d'activation ReLU. Cette couche de convolution est suivie par une couche de batch normalization pour maintenir la sortie moyenne proche de 0 et l'écart type de sortie proche de 1. La sortie de ce bloc est 64 feature maps de taille 112×112 .
- Bloc 5 : Ce bloc est une répétition du bloc 4.
- Bloc 6 : Une couche de max pooling est appliquée au bloc 5, ce qui réduit la taille de l'image à 56×56 . Cette couche est suivie d'une couche de dropout.
- Bloc 7 : Les 64 feature maps de taille 56×56 sont suivies d'une couche de convolution avec 128 filtres de taille 3×3 . Cette couche est suivie d'une batch normalization.
- Bloc 8 : Ce bloc est une répétition du bloc 7.
- Bloc 9 : Les 128 feature maps de taille 28×28 sont données comme entrée à une couche de max pooling suivie d'une couche de dropout.

Nous appliquons une opération de flatten sur les 128 feature maps de taille 28×28 , ce qui donne un vecteur de taille 100352.

Après la couche de flatten, nous utilisons un réseau de neurones composé de deux couches fully connected. La première couche, composée de 256 neurones, utilise la fonction d'activation ReLU. Cette couche est suivie par une couche de batch normalization et d'une couche de dropout. La deuxième couche fully connected est une couche de sortie composée de deux neurones. Cette couche utilise la fonction d'activation sigmoïde, qui permet de calculer la distribution de probabilité des différentes classes et utilise l'optimiseur ADAM avec un taux d'apprentissage de 0,001. La figure III.13 donne l'architecture détaillée de notre modèle.

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 224, 224, 32)	896
batch_normalization (BatchNormalization)	(None, 224, 224, 32)	128
conv2d (Conv2D)	(None, 224, 224, 32)	9248
batch_normalization (BatchNormalization)	(None, 224, 224, 32)	128
max_pooling2d (MaxPooling2D)	(None, 112, 112, 32)	0
dropout (Dropout)	(None, 112, 112, 32)	0
conv2d (Conv2D)	(None, 112, 112, 64)	18496
batch_normalization (BatchNormalization)	(None, 112, 112, 64)	256
conv2d (Conv2D)	(None, 112, 112, 64)	36928
batch_normalization (BatchNormalization)	(None, 112, 112, 64)	256
max_pooling2d (MaxPooling2D)	(None, 56, 56, 64)	0
dropout (Dropout)	(None, 56, 56, 64)	0
conv2d (Conv2D)	(None, 56, 56, 128)	73856
batch_normalization (BatchNormalization)	(None, 56, 56, 128)	512
conv2d (Conv2D)	(None, 56, 56, 128)	147584
batch_normalization (BatchNormalization)	(None, 56, 56, 128)	512
max_pooling2d (MaxPooling2D)	(None, 28, 28, 128)	0
dropout (Dropout)	(None, 28, 28, 128)	0
flatten (Flatten)	(None, 100352)	0
dense (Dense)	(None, 256)	25690368
batch_normalization (BatchNormalization)	(None, 256)	1024
dropout (Dropout)	(None, 256)	0
dense (Dense)	(None, 2)	514

Figure III.13 : Architecture de notre modèle 1 (modèle personnalisé).

III.5.2 Modèles utilisant le transfer learning

Le transfert d'apprentissage (transfer learning) est une technique de machine learning où un modèle préalablement entraîné sur une tâche est réutilisé comme point de départ pour une autre tâche similaire. Cette méthode est particulièrement utile lorsque les données disponibles pour la nouvelle tâche sont limitées. En transférant les connaissances d'un modèle bien entraîné, on peut améliorer les performances et accélérer le processus d'entraînement pour la

nouvelle tâche. Le transfert d'apprentissage est couramment utilisé dans la vision par ordinateur et le traitement du langage naturel.

La technique de transfer learning bénéficie de plusieurs avantages :

- ✓ Réduction du temps d'entraînement : Le modèle démarre avec des poids préalablement appris, réduisant ainsi le temps nécessaire pour converger.
- ✓ Meilleure performance : Les modèles bénéficient des connaissances acquises sur des ensembles de données plus vastes et variés.
- ✓ Moins de données nécessaires : Permet d'obtenir de bons résultats même avec des ensembles de données limités pour la nouvelle tâche.

Dans notre application, nous utilisons le transfert d'apprentissage avec deux réseaux CNN : VGG16 et EfficientNet. Ces deux réseaux sont largement utilisés pour des tâches de vision par ordinateur, telles que la classification d'images et la détection des maladies.

III.5.2.1 Transfer learning avec VGG16 (Modèle 2)

VGG16 est un modèle CNN proposé par l'Université d'Oxford. Ce réseau est connu pour sa simplicité avec 16 couches de convolution suivies de couches de pooling et entièrement connectées. Il se distingue par l'utilisation de filtres 3x3 dans les couches de convolution et l'utilisation de couches entièrement connectées à la fin pour la classification. C'est un modèle profond mais simple à comprendre et à implémenter. L'architecture du modèle 2 est illustrée dans les figures III.14 et III.15.

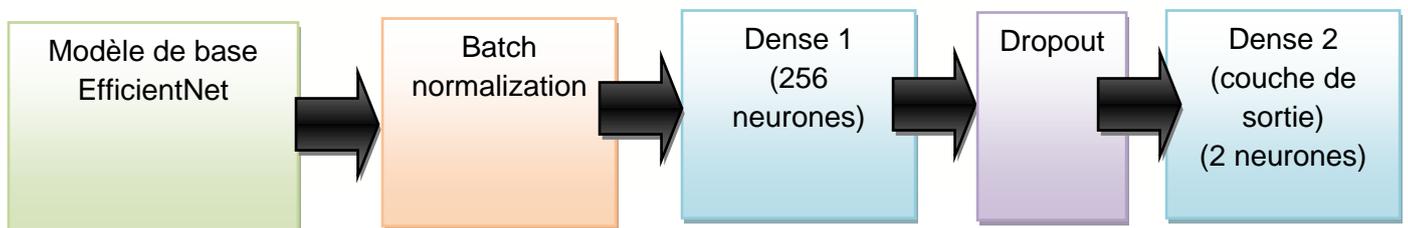


Figure III.14 : Architecture du modèle de transfert learning avec VGG16.

Layer (type)	Output Shape	Param #
vgg16 (Functional)	(None, 512)	14714688
batch_normalization_7 (Batch Normalization)	(None, 512)	2048
dense_2 (Dense)	(None, 256)	131328
dropout_4 (Dropout)	(None, 256)	0
dense_3 (Dense)	(None, 2)	514
=====		
Total params: 14848578 (56.64 MB)		
Trainable params: 14847554 (56.64 MB)		
Non-trainable params: 1024 (4.00 KB)		

Figure III.15 : Différents composants et paramètres du modèle de transfer learning avec VGG16.

III.5.2.2 Transfer learning avec EfficientNet (Modèle 3)

EfficientNet est une famille de modèles de réseaux neuronaux qui optimise à la fois la précision et l'efficacité en ajustant uniformément la profondeur, la largeur et la résolution des réseaux. Ce réseau se caractérise par l'utilisation d'un modèle de redimensionnement pour augmenter la taille du réseau de manière plus efficace. Il utilise des blocs MBConv (Mobile Inverted Bottleneck Convolution) pour améliorer la performance et l'efficacité énergétique. Ce modèle est généralement plus performant que les modèles traditionnels tels que VGG16 et InceptionV3, tout en nécessitant moins de ressources pour une précision comparable ou supérieure. L'architecture du modèle 2 est illustrée dans les figures III.16 et III.17.

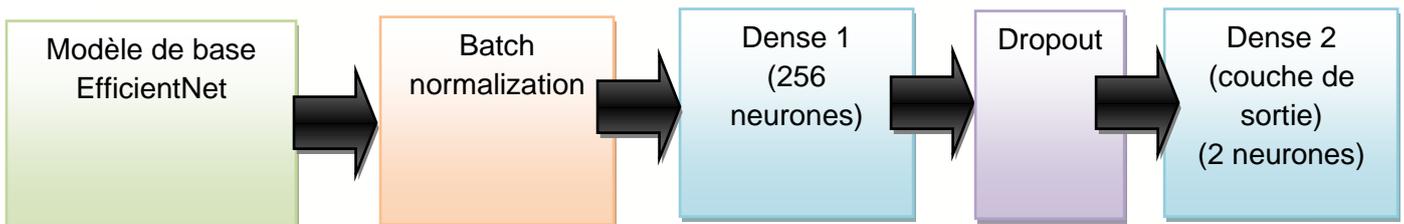


Figure III.16 : Architecture du modèle de transfer learning avec EfficientNet.

Layer (type)	Output Shape	Param #
efficientnetb3 (Functional)	(None, 1536)	10783535
batch_normalization_8 (Batch Normalization)	(None, 1536)	6144
dense_4 (Dense)	(None, 256)	393472
dropout_5 (Dropout)	(None, 256)	0
dense_5 (Dense)	(None, 2)	514
Total params: 11183665 (42.66 MB)		
Trainable params: 11093290 (42.32 MB)		
Non-trainable params: 90375 (353.03 KB)		

Figure III.17 : Différents composants et paramètres du modèle de transfer learning avec EfficientNet.

III.6 Résultats obtenus avec notre modèle 1

III.6.1 Résultats d'entraînement et de validation de notre modèle 1

Cette section présente les différents résultats obtenus par notre modèle. Ces résultats sont exprimés en termes de précision et d'erreur.

Les paramètres utilisés par notre modèle sont les suivants :

Algorithme d'apprentissage : Adam

Nombre d'époques : 20 époques

Learning rate : 0.001

Fonction de perte : binary_crossentropy.

Batch : 40

Les valeurs d'accuracy et de la fonction de perte pour ce modèle, à la fois pour l'entraînement et la validation, sont illustrées sur la figure III.18.

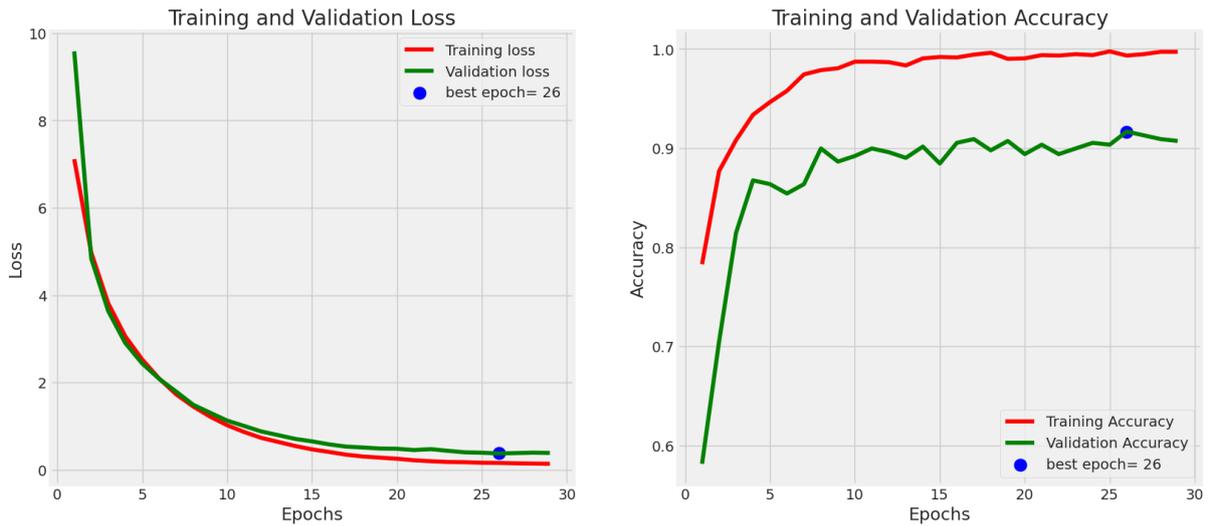


Figure III.18 : Valeurs d'accuracy et de perte dans les phases d'entraînement et de validation pour notre modèle 1.

III.6.2 Résultats obtenus dans la phase de teste

Après l'entraînement de notre modèle et la construction de ses poids finaux, nous testons notre modèle sur les images de la base de test. La figure III.19 présente le résultat d'une image aléatoire prise de la base de test ; le résultat montre que cette image représente un cancer.

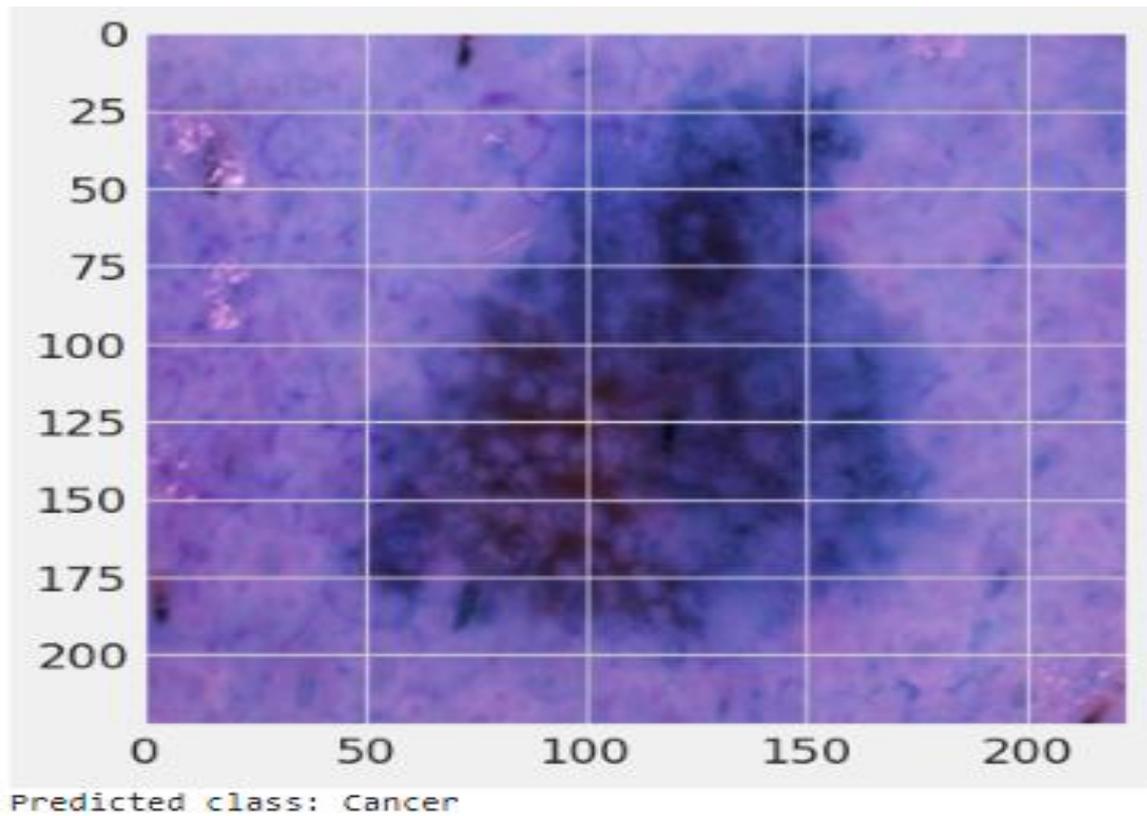


Figure III.19: Classification d'une image aléatoire de la base de teste.

La figure III.20. Présente la matrice de confusion obtenu du modèle.

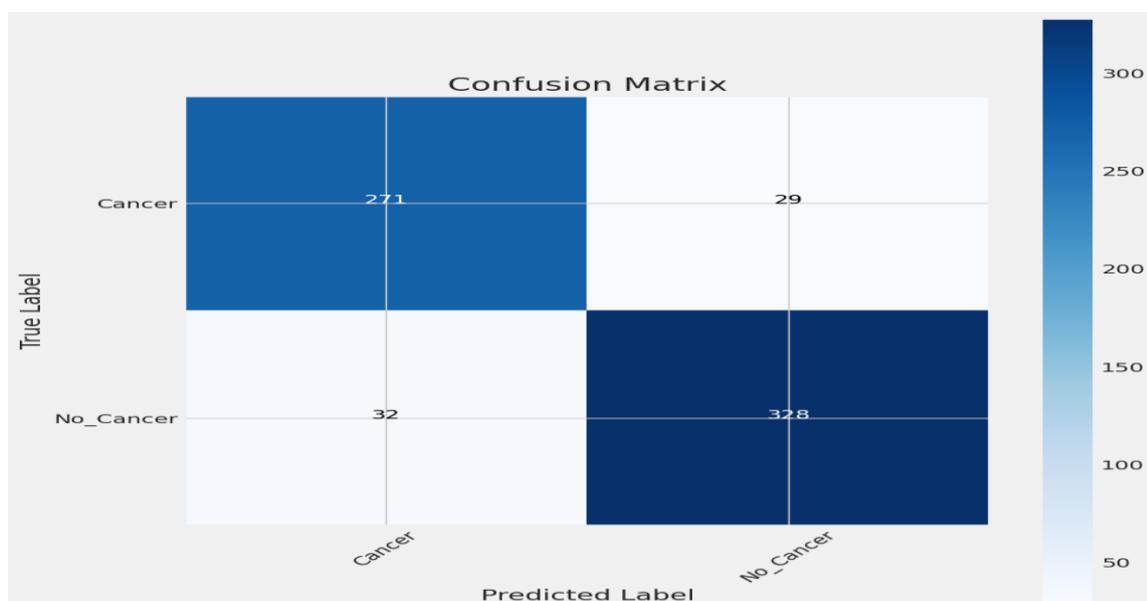


Figure III.20: Matrice de confusion obtenue.

V.7 Résultats obtenus avec notre modèle 2 (transfer learning avec VGG16)

La figure III.21 présente les résultats de l'entraînement du modèle de transfert learning avec VGG16.

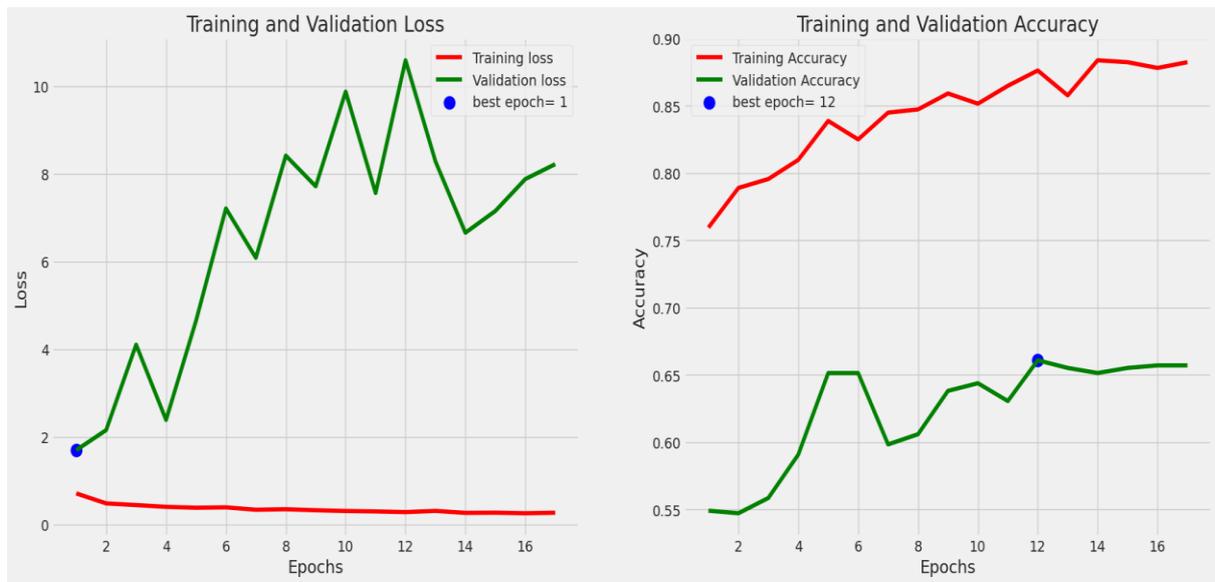


Figure III.21 : Valeurs d'accuracy et de perte dans les phases d'entraînement et de validation pour notre modèle 2.

III.8 Résultats obtenus avec notre modèle 3 (transfer learning avec EfficientNet)

La figure III.22 présente les résultats de l'entraînement du modèle de transfert d'apprentissage avec EfficientNet.

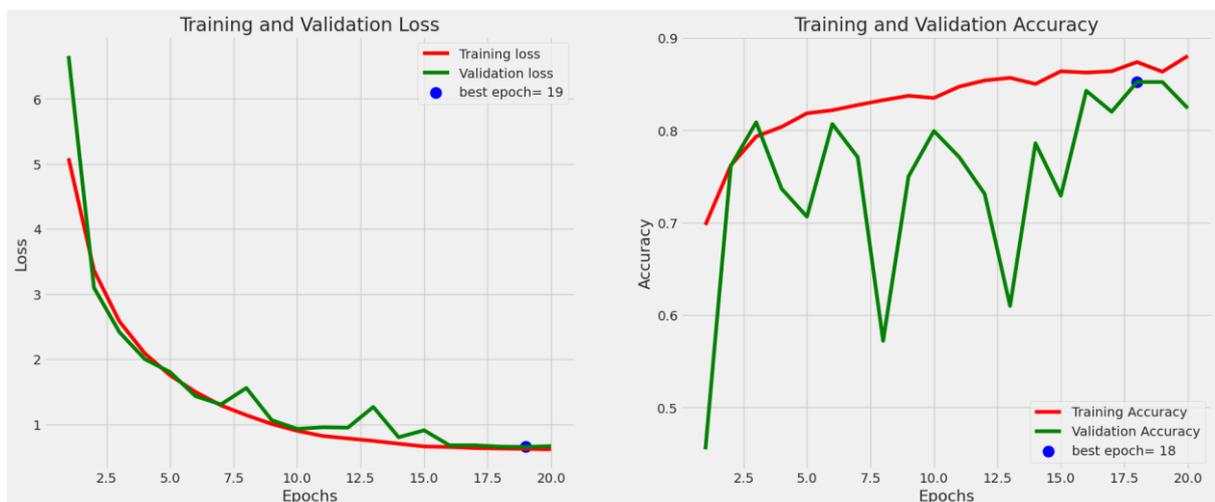


Figure III.22 : Valeurs d'accuracy et de perte dans les phases d'entraînement et de validation pour notre modèle 3.

III.9 Comparaison des différents résultats

Après avoir analysé les résultats de chaque modèle, il est clair que le modèle 1 a obtenu les meilleurs résultats. Ces performances élevées sont attribuées au grand nombre de couches utilisées et à l'efficacité de l'architecture en bloc. Cependant, il convient de noter que le temps d'exécution était considérablement plus long en raison de la complexité du modèle.

Les modèles basés sur le transfert d'apprentissage ont également produit de bons résultats. Nous avons observé une supériorité du modèle EfficientNet par rapport à VGG16 en termes de précision et d'efficacité.

L'utilisation des CNN se révèle être une approche prometteuse pour la classification des maladies, en particulier le cancer de la peau. De plus, nos résultats suggèrent que l'utilisation du transfert learning est bénéfique pour les CNN car il permet aux modèles de commencer avec des poids pré-appris, ce qui améliore leur capacité à apprendre le problème ciblé dès le début de l'entraînement et garantit une convergence plus rapide vers un minimum local optimal.

III.10 Conclusion

Dans ce chapitre, nous avons présenté une approche de détection du cancer de la peau basée sur les réseaux de neurones convolutionnels. Pour ce faire, nous avons utilisé trois modèles et avons examiné leurs performances en termes de précision et d'erreur.

La comparaison des résultats obtenus a révélé que plusieurs facteurs influent sur la qualité des résultats, notamment le nombre d'époques d'entraînement, la taille de la base de données et la profondeur des réseaux. De plus, l'utilisation d'architectures spécifiques adaptées à chaque type d'images et à chaque type de cancer à détecter s'est avérée cruciale pour obtenir de meilleurs résultats.

Nous avons également constaté que l'utilisation du transfert d'apprentissage conduit à des performances prometteuses. En effet, le démarrage de l'apprentissage à partir de poids pré-entraînés permet aux modèles de se rapprocher plus rapidement de l'optimum, contrairement au démarrage avec des poids aléatoires.

Conclusion générale

La classification d'images est une tâche importante dans le domaine de la vision par ordinateur, de la reconnaissance d'objets et de l'apprentissage automatique. Grâce à l'apprentissage profond (Deep Learning), les avancées en intelligence artificielle dans le développement de grandes applications sont devenues très rapides.

La détection et la classification du cancer de la peau par l'intelligence artificielle et l'apprentissage profond sont actuellement considérées comme des approches indispensables. Cela est dû à l'augmentation du nombre de cas de cancer de la peau et à la nécessité de méthodes de diagnostic précises, rapides et non invasives. Selon l'Organisation Mondiale de la Santé (OMS), environ 2 à 3 millions de cas de cancers non mélanomes et 132 000 cas de mélanomes malins sont diagnostiqués chaque année dans le monde.

Dans ce projet, nous avons présenté notre approche de détection et de classification du cancer de la peau en utilisant des images médicales de la peau. Pour cela, nous avons utilisé le deep learning et en particulier les réseaux de neurones convolutionnels (CNN) comme noyau de notre approche. Les CNNs ont démontré leur performance ces dernières années, jouant un rôle crucial dans la compréhension du contenu des images et dans les tâches de segmentation, de classification, de détection et d'extraction d'objets.

Le choix des CNNs est justifié par la simplicité et l'efficacité de la méthode. L'objectif de ce projet était de détecter le cancer de la peau de manière rapide et précise pour améliorer le diagnostic précoce et réduire la mortalité associée à cette maladie. Nous avons proposé un modèle CNN spécifique pour ce type de cancer, notre modèle a montré son efficacité pour la détection du cancer de la peau.

Enfin, ce travail a permis de dégager de nombreuses perspectives :

1. Ce projet peut être approuvé au niveau des hôpitaux en raison des données d'entraînement confirmées par des dermatologues.
2. Il sera intéressant dans le futur d'améliorer ce système pour pouvoir détecter d'autres types de cancers de la peau et d'autres maladies dermatologiques.

Références bibliographiques

- [1] M. Celebi, Y. Aslandogan, W. Stoecker, H. Iyatomi, H. Oka and X. Chen. Unsupervised border detection in dermoscopy images. *Skin Research and Technology*, vol. 13, no. 4, pp. 454-462, 2007.
- [2] R. Kenet, T. Fitzpatrick. Reducing mortality and morbidity of cutaneous melanoma: a six-year plan, identifying high and low risk pigmented lesions using epiluminescence microscopy. *The Journal of Dermatology*, vol. 21, no. 11, pp. 881-884, 1994.
- [3] K. Madison. Barrier function of the skin: "la raison d'être" of the epidermis. *J Invest Dermatol*, vol. 121, no. 2, pp. 231-241, 2003.
- [4] M. Stücker, A. Struk, P. Altmeyer, M. Herde, H. Baumgärtl, D. Lübbers. The cutaneous uptake of atmospheric oxygen contributes significantly to the oxygen supply of human dermis and epidermis. *The Journal of Physiology*, vol. 538, no. 3, pp. 985-994, 2002.
- [5] J. Mothoneos. Cancer council, *Understanding Skin Cancer: A guide for people with cancer , their families and friends*, January 2020.
- [6] "World Health Organization," [Online]. Site: <http://www.who.int/en/>. [Consulté Juin 2024].
- [7] "Qu'est-ce qu'un cancer de la peau ?" [Online]. Site: <https://www.e-cancer.fr/Comprendre-prevenir-depister/Se-faire-depister/Depistage-des-cancers-de-la-peau/Les-cancers-de-la-peau> [Consulté mai 2024].
- [8] "Basal Cell Carcinoma (BCC)," [Online]. Site: <https://www.skincancer.org/skin-cancer-information/basal-cell-carcinoma>. [Consulté Mars 2024].
- [9] "Melanoma Treatment for Health Professionals," [Online]. Site: <https://web.archive.org/web/20150704213842/http://www.cancer.gov/types/skin/hp/melanoma-treatment-pdq>. [Consulté Mai 2024].
- [10] B. Cakir, P. Adamson, C. Cingi. Epidemiology and economic burden of nonmelanoma skin cancer. *Facial Plastic Surgery Clinics of North America*, vol. 20, no. 4, pp. 419-422, 2012.
- [11] "Signes et symptômes du cancer de la peau autre que le mélanome" [Online] Site : <https://cancer.ca/fr/cancer-information/cancer-types/skin-non-melanoma/signs-and-symptoms> [Consulté Juin 2024].
- [12] "Diagnostic d'un mélanome de la peau" [Online] Site : <https://www.e-cancer.fr/Patients-et-proches/Les-cancers/Melanome-de-la-peau/Diagnostic-et-bilan-initial> [Consulté Juin 2024].
- [13] "Echographie cutanée haute résolution en dermatologie esthétique" [Online] Site : <https://www.realites-dermatologiques.com/2013/03/echographie-cutanee-haute-resolution-en-dermatologie-esthetique/> [Consulté Mai 2024].
- [14] P. Kittler H, K. Wolff, M. Binder. Diagnostic accuracy of dermoscopy. *Lancet Oncol*, vol. 3, pp. 159-165, 2002.
- [15] C. R. Qi. PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation. *Computer Science, Computer Vision and Pattern Recognition*, avril 2017.
- [16] Top 15 Deep Learning applications that will rule the world in 2018 and beyond: <https://www.linkedin.com/pulse/top-15-deep-learning-applications-rule-world-2018-beyond-mittal>. [Consulté juin 2024].

- [17] "Réseaux de neurones" [Online] Site: <https://www.math.univ-toulouse.fr/~besse/Wikistat/pdf/st-m-app-rn.pdf> [Consulté Juin 2024]
- [18] "Neurone artificiel" [Online] Site: <https://www.cnil.fr/fr/definition/neurone-artificiel> [Consulté Mars 2024]
- [19] "Comprendre les réseaux de neurones" Site: <https://moncoachdata.com/blog/comprendre-les-reseaux-de-neurones/>[Consulté Février 2024]
- [20]"Perceptron multicouches" [Online] Site: https://pageperso.lis-lab.fr/alexis.nasr/Ens/MASCO_AA/mlp.pdf [Consulté Mars 2024]
- [21] T. Stérin. Réseaux de neurones récurrents et mémoire : application à la musique. Licence d'informatique. Université Claude Bernard Lyon, 2016.
- [22] S. Dupond. A thorough review on the current advance of neural network structures. *Annual Reviews in Control.* vol. 14, pp. 200–230, 2019.
- [23] O. Abiodun, A. Jantan, O. Omolara, K. Dada, M. Nachaat, A. Humaira. State-of-the-art in artificial neural network applications: A survey. *Heliyon*, vol. 4, no. 11, 2018. Article e00938, 10.1016/j.heliyon.2018.e00938
- [24] A. Tealab. Time series forecasting using artificial neural networks methodologies: A systematic review. *Future Computing and Informatics Journal*, vol. 3, no. 2, pp 334–340, décembre 2018.
- [25] A. Graves, M. Liwicki, S. Fernandez, R. Bertolami, H. Bunke, J. Schmidhuber. A Novel Connectionist System for Improved Unconstrained Handwriting Recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 31, no. 5, pp. 855–868, 2009.
- [26] H. Sak, F. Beaufays. Long short-term memory recurrent neural network architectures for large scale acoustic modeling. *Proceedings of the Annual Conference of the International Speech Communication Association, INTERSPEECH*, pp. 338-342, 2014.
- [27] Le principe du filtre convolutionnel : <https://i.stack.imgur.com/> (dernier accès février 2022)
- [28] Convolutional neural network [Online] Site : <https://datascientest.com/convolutional-neural-network> [Consulté Mars 2024]
- [29] Basic Introduction to Convolutional Neural Network in Deep Learning : [Online] Site : <https://www.analyticsvidhya.com/blog/2022/03/basic-introduction-to-convolutional-neural-network-in-deep-learning/> (Consulté juin 2024)
- [30] I. Goodfellow, Y. Bengio, A. Courville. 6.2.2.3 Softmax Units for Multinoulli Output Distributions. *Deep Learning*, MIT Press, pp. 180–184, 2016.
- [31] A. Esteva, K. Chou, S. Yeung, N. Naik, A. Madani, A. Mottaghi, Y. Liu, E. Topol, J. Dean, R. Socher. Deep learning-enabled medical computer vision. *Deep learning-enabled medical computer vision.* *npj Digit. Med.* 4, 5 (2021). <https://doi.org/10.1038/s41746-020-00376-2>.
- [32] Recep Erol. Skin cancer malignancy classification with transfer learning. Thèse de master, Conway, Arkansas, 2018.
- [33] Fekrache Dalila. Traitement d'images comme outil de diagnostic du cancer de la peau. Thèse de doctorat, Université Mouloud Mammeri de Tizi-Ouzou, 2017.
- [34] Gunther Eysenbach, Skin Cancer Classification Using Convolutional Neural Networks: Systematic Review. doi:10.2196/11936 , 17 Octobre 2018.

[35] Aiche rachid. Application Mobile Pour L'aide A La Diagnostique Du Cancer De La Peau. Thèse de master, Université Mohamed Boudiaf, Msila, 2016.

[36] Mohammad Ali Kadampur, Sulaiman Al Riyaae. Skin cancer detection: Applying a deep learning-based model driven architecture in the cloud for classifying dermal cell images. Al-Imam Muhammed Ibn Saud Islamic University, Riyadh, 2020.

[37] Python: <https://techterms.com/definition/python>. (Consulté Février 2024)

[38] Colab : <https://colab.research.google.com/>. (Dernier accès juin 2024)

[39] Conda: <http://conda.pydata.org/docs/>. (dernier accès juin 2024)

[40] Outils de développement logiciel :
<https://outils-developpement-logiciel.sodevlog.com/2020/10/cest-quoi-loutil-jupyter-notebook.html>.
(dernier accès juin 2024)

[41] Keras: <https://www.tensorflow.org/guide/keras?hl=fr>. (dernier accès juin 2024)