

الجمهورية الجزائرية الديمقراطية الشعبية

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

وزارة التعليم العالي والبحث العلمي

MINISTERE DE L'ENSEIGNEMENT SUPERIEUR

ET DE LA RECHERCHE SCIENTIFIQUE



UNIVERSITE MOHAMED SEDDIK BENYAHIA JIJEL

Faculté des sciences et de la technologie

Département de Electronique

N° :/2023

MEMOIRE DE MASTER

DOMAINE: Sciences et Technologies

FILIERE: Electronique

SPECIALITE: Electronique des Systèmes Embarqués

Thème

Classification d'images des cellules sanguines leucémiques à l'aide des techniques d'apprentissage profond

Présenté Par : M^{elle} farah NOUAR

Encadré Par : Dr. Sabrina BOUATMANE

M^{elle} rima BOUCHENINE

Date de soutenance: 25/06/2023

Jury de Soutenance

Président : Dr. N. TALBI

MCB

UMSB

Encadreur : Dr. S. BOUATMANE

MCB

UMSB

Examineur 1: Dr. I. BOURAOU

MCA

UMSB

Promotion : 2022 /2023



Remerciements

Avant tout, je remercie « Dieu », le tout puissant et le miséricordieux pour la volonté et la patience qu'il m'a attribuée. Qu'il soit loué pour l'aide qu'il m'a fournie afin d'achever mes études et pour m'avoir guidé dans le droit chemin dans ma vie.

Je tiens à exprimer mes vifs remerciements à :

Ma encadreur Mm : Sabrina BOUATMANE, de m'avoir aidé à réaliser le travail demandé dans ce projet de fin d'étude.

Tous les membres du jury d'avoir participé à la commission des examinateurs en vue d'une évaluation prompte et à sa juste valeur.

Tous ceux qui ont contribué de loin ou près à la réalisation de ce travail



DÉDICACE

Je dédie ce travail :

*À mes très chers parents pour leur soutien durant toute ma vie d'études
et sans Lesquels je n'aurais jamais devenu*

Ce que je suis.

À mes frères fares, mouad, biles

Aux personnes les plus chères à mon cœur houda, chahira, siline

*À tous ceux qu'ils m'aiment, ma famille, mes amis, mes collègues, pour
tous ceux qu'ils portent les sens de l'amitié, l'amour la fidélité*

À tous mes amis.

*À toutes les professeurs et enseignants que j'ai eu durant tout mon
cursus scolaire et qui m'ont permis de réussir Dans mes études.*

*Et à tous ceux qui ont contribué de près ou de loin pour que ce Projet soit
possible, je vous dit*

Merci

BOUCHENNINE RIMA



Dédicace

Je dédie cet humble travail

À mes chers parents ma mère et mon père

*Pour leur patience, leur amour, leur soutien inconditionnel et leurs
encouragements.*

À mes frères Adem et Oussama et à toute ma famille.

À mes amis et mes camarades

À tous ceux qui ont m'enseigné tout au long de ma vie Scolaire.

*À ma binôme Rima , et à tous ceux qui ont contribué de près ou de loin
pour que ce projet soit possible , je vous dis merci .*

Farah

ملخص

في هذا العمل نقدم تصنيف صور لنسيج الدم للكشف السريع عن سرطان الدم الحاد لدى الأطفال (ALL) بالاعتماد على التعلم العميق حيث تم استخدام الشبكات العصبية التلافيفية (CNN) والمصنف SVM الذي يعد من أكثر الطرق كفاءة في مجال تصنيف الصور. انطلاقاً من قاعدة البيانات C-NMC 2019 تم استخراج الميزات من مختلف الشبكات العصبية التلافيفية (CNN) فأظهرت أداء مقبول. ومن أجل تحسين النتائج قمنا بدمج عدة شبكات عصبية تلافيفية فكانت نتائج التصنيف جيدة. ومن جهة أخرى قمنا باختيار الميزات الأكثر أهمية عن طريق خوارزمية Relief حيث نتج عن ذلك تحسين النتائج من خلال مراقبة مصفوفة التشتت ومنحنى ROC والحصول على نموذج أبسط للتصنيف.

Résumé

Dans ce travail, nous présentons une classification des images de tissu sanguin pour la détection rapide de la leucémie aiguë chez l'enfant (ALL) basée sur l'apprentissage profond, où les réseaux de neurones convolutionnels (CNN) et le classificateur SVM ont été utilisés, qui est l'une des méthodes les plus efficaces dans le domaine de la classification d'images. Basé sur la base de données C-NMC 2019, les caractéristiques ont été extraites de divers réseaux de neurones convolutionnels (CNN) et ont montré des performances acceptables. Afin d'améliorer les résultats, nous avons fusionné plusieurs réseaux de neurones convolutionnels, D'autre part, nous avons sélectionné les caractéristiques les plus importantes via l'algorithme Relief, cela a permis d'améliorer les résultats en terme de la matrice de confusion et la courbe ROC, et d'obtenir un modèle de classification plus simple.

Abstract

In this work, we present a classification of blood tissue images for rapid detection of childhood acute leukemia (ALL) based on deep learning, where convolutional neural networks (CNN) and SVM classifier were used, which is one of the most effective methods in the field of image classification. Based on C-NMC 2019 database, features were extracted from various convolutional neural networks (CNN) and showed acceptable performance. In order to improve the results, we merged several convolutional neural networks, On the other hand, we selected the most important features via the Relief algorithm, this made it possible to improve the results in terms of the confusion matrix and the ROC curve, and to obtain a simpler classification model.

Sommaire

Remerciement	
Dédicace	
Résumé	
Sommaire	I
Liste des tableaux	III
Liste des figures	IV
Liste des abréviations	VI
Introduction générale.....	1

Chapitre I

Apprentissage artificielle et la vision par ordinateur

I.1 Introduction.....	3
I.2 Leucémie aiguë lymphoblastique.....	4
I.3 Représentation des images numériques de microscopie sanguine.....	6
I.4 Les différents types d'image.....	7
I.5 Système de Vision par ordinateur	8
I.5.1 Prétraitements.....	9
I.5.2 La Segmentation.....	10
I.5.3 Extraction des caractéristiques.....	14
I.5.3.1 Les caractéristiques de forme	16
I.5.3.2 Les caractéristiques de textures	17
I.6 Apprentissage automatique	18
I.7 la classification	22
I.7.1 Présentation de certaines techniques de la classification	22
I.7.2 Evaluation de la Classification.....	25
I.7.2.1 Matrice de confusion	25
I.7.2.2 Courbe ROC (Received Operating Characteristic)	26
I.8 Conclusion	27

Chapitre II

Réseaux de neurone convolutionnels

II.1 Introduction	29
II.2 De l'apprentissage automatique (machine Learning) à l'apprentissage profond (Deep Learning)	29
II.3 Historique de Deep Learning.....	31
II.4 les réseaux de neurones artificiels	31

II.5 Principe de fonctionnement de réseaux de neuronaux (RN)	32
II.6 Présentation de quelques types de réseaux de neuronaux	32
II.6.1 Neurone Formel	32
II.6.2 Les Réseaux de Neurones Multicouches	33
II.6.3 Les Réseaux de Neurones Récurents (ou bouclés)	33
II.6.4 Réseau de Neurone Hopfield	34
II.7 Les réseaux de neurones convolutionnels	34
II.8 Architecture d'un Les réseaux de neurones convolutionnels (CNN)	35
II.8.1 Couche de convolution(CONV).....	35
II.8.2 Couche de Pooling	37
II.8.3 la couche ReLU	38
II.8.4 Couche fully-connected	39
II.8.5 Couche de perte (LOSS)	40
II.9.Choix des paramètres	40
II.9.1 Nombre de filtres	40
II.9.2 Forme du filtre	40
II.9.3 Forme du Max Pooling	41
II.10 Les réseaux CNN	41
II.11 Transfer Learning : Adapter des CNN pré-entraînés.....	45
II.12. Conclusion.....	47

Chapitre III

Tests et Résultats

III.1. Introduction	49
III.2. La base de données.....	49
III.3 Étude expérimentale.....	51
III.3.1. Prétraitements.....	51
III.3.2. Extraction des caractéristiques :.....	52
III.3.3. Sélection des caractéristiques (par L'algorithme Relief)	54
III.3.4. Classification.....	57
III.4. Conclusion.....	60
Conclusion général.....	62
Référence bibliographiques.....	63

Liste des tableaux

Tableau III.1 : Nombre d'échantillons dans les ensembles d'entraînement, de validation et de test. Le nombre de patients est indiqué entre parenthèses..... 50

Tableau III.2 : Nombre des images utilisées 50

Tableau III.3 : les couches et le nombre de caractéristique des quelque réseaux utilisé 53

Tableau III.4 : taux de classification des réseaux utilisés 57

Tableau III.5: taux de classification et le nombre total des caractéristiques..... 58

Tableau III.6 : le taux de classification et le nombre de caractéristiques sélectionnées par Relief..... 58

Liste des figures

Figure I.1 : a) image sanguine normal. (b) image sanguine leucémiques_ Les leucémies se divisent en quatre principaux types :..... 4

Figure I.2 : les composants du sang et les types de leucémies..... 5

Figure I.3 : représentation de l’image numérique microscopique du sang 7

Figure I.4 : Exemple d’une image binaire..... 7

Figure I.5 : Exemple d’image en niveau de gris et sa quantification..... 8

Figure I.6 : les couleurs Rouge Vert Bleu(RVB)..... 8

Figure I.7: Les étapes d’un système de vision par ordinateur 9

Figure I.8 : Image avec et sans bruit 9

Figure I.9 : exemple de segmentation des images 11

Figure I.10 : Méthodes de segmentation utilisées en WBC 12

Figure I.11 : a) Seuillage simple d’un histogramme b) Seuillage multiple d’un histogramme. 12

Figure I.12 : description des caractéristiques de l’image..... 15

Figure I.13 : méthode d’extraction de caractéristique pour les images microscopique sanguines [17] 16

Figure I.14 : La différence entre la cellule normale et cellule cancéreuse..... 17

Figure I.15 : Exemple de l’utilisation des caractéristiques statistiques GLCM..... 18

Figure I.16: Les approches et les algorithmes de l’apprentissage automatique 19

Figure I.17 : L’apprentissage supervisé 20

Figure I.18 : L’apprentissage non supervisé 21

Figure I.19: Méthode de KNN. 23

Figure I.20 : Problème de classification à deux classes avec une séparatrice linéaire 23

Figure I.21 : Problème de classification à deux classes avec une séparatrice non linéaire .. 24

Figure I.22 : Hyperplan optimal avec une marge maximale 24

Figure I.23 : Exemple de la matrice de confusion. 25

Figure I.24 : Indicateurs principaux..... 26

Figure I.25: Exemple d’illustration de la courbe ROC. 26

Figure I.26 : prédite négatif et positif de AUC. 27

Figure II.1 : La relation entre l’IA, ML et le Deep Learning..... 29

Figure II.2 : Représentation de la différence entre les techniques d’apprentissage automatique et deep Learning pour la classification de la leucémie..... 30

Figure II.3: Schéma d’un réseau de neurones avec deux couches cachées..... 32

Figure II.4: Modèle d'un neurone formel.	32
Figure II.5 : structure d'un réseau de neurones multicouche.....	33
Figure II.6 : Neurones bouclés.....	33
Figure II.7 : Schéma représentant l'architecture d'un CNN	35
Figure II.8 : Exemple de filtre de taille (3*3)	36
Figure II.9 : Exemple des features maps résultants de la convolution.....	37
Figure II.10: max et arevage pooling	38
Figure II.11: Représentation graphique de la fonctionnalité Relu.	39
Figure II.12: fully-connected layers.....	39
Figure II.13: Architecture of convolutional neural network Net	41
Figure II.14: Architecture of convolutional neural network AlexNet	42
Figure II.15: Architecture de Google Net.	43
Figure II.16: Architecture of convolutional neural network VGG	44
Figure II.17 : exemple de modèle de CNN utilisé pour la classification d'images	46
Figure II.18 : le transfer learning en utilisant le Fine tuning	47
Figure III.1 : Exemple des images ALL	50
Figure III. 2 : Exemple des images HEM	50
Figure III.3 : Approche implémentée pour la classification de la leucémie	51
Figure III. 4 : les étapes de prétraitement.....	52
Figure III. 5 : Visualisation des caractéristiques les plus saillantes des couches de convolution et de pooling.....	54
Figure III. 6: Pseudo code de l'algorithme Relief de base.....	55
Figure III .7 :les caractéristiques importantes sont sélectionnées à l'aide d'algorithmes Relief.....	56
Figure III. 8 : La matrice de confusion et La courbe ROC d'un densenet201+ mobilenetv2	58
Figure III. 9 : La matrice de confusion et La courbe ROC d'un densenet201 +Resnet101...	59
Figure III. 10 : La matrice de confusion et La courbe ROC d'un inceptionresnetV2+ Google net.....	59

Liste des abréviations

CNN : Convolutional Neural Network.

DL : Deep Learning.

FC : Fully Connected.

IA : Intelligence Artificielle.

MLP : Multi-Layer Perceptron.

Relu : Rectified Linear Units.

RNN : Récurrent Neural Network.

ROC : Received Operating Caractéristique.

SVM : Machines à Vecteurs de Supports

RNN :Recurrent Neural Networks

POOL : Pooling

CONV : Convolution

KNN : K-nearest neighbors

VAO :vision assistée par ordinateure

ML : machine learning

ALL : Acute lymphocytic leukemia

WBC : White Blood Cell

GLCM : grey level coccurrence matrix

RL : Reinforcement Learning

AUC : Area Under the Curve

Introduction générale

Introduction générale

La détection précoce de la leucémie a toujours été un défi majeur pour les chercheurs, les médecins et les hématologistes. Les symptômes tels que l'hypertrophie des ganglions lymphatiques, la pâleur, la fièvre et la perte de poids sont courants dans la leucémie, mais ils peuvent également être présents dans d'autres maladies [1]. En raison de la nature légère de ces symptômes, le diagnostic de la leucémie aux stades précoces est difficile. Bien que l'évaluation microscopique du frottis sanguin périphérique (PBS) soit la méthode de diagnostic la plus courante, l'analyse des échantillons de moelle osseuse reste la référence absolue pour le diagnostic de la leucémie [2].

Au cours des deux dernières décennies, des études ont exploré l'utilisation de l'apprentissage automatique (ML) et de techniques de diagnostic assisté par ordinateur dans l'analyse d'images de laboratoire, dans le but de surmonter les limites d'un diagnostic tardif de la leucémie et de caractériser ses sous-groupes. Ces études ont examiné des images de frottis sanguins pour diagnostiquer, différencier et compter les cellules dans différents types de leucémie [3].

L'apprentissage automatique est une branche bien connue de l'intelligence artificielle qui implique l'utilisation d'algorithmes et de relations mathématiques. Il a été rapidement adopté dans le domaine de la recherche clinique. En exploitant la capacité des ordinateurs à apprendre à partir de données sans programmation explicite, l'apprentissage automatique a connu un succès remarquable dans le domaine du diagnostic des maladies [4]. Des études ont démontré que les méthodes d'apprentissage automatique facilitent grandement la prise de décision médicale en extrayant et en analysant les caractéristiques des images médicales complexes. Avec l'augmentation du nombre d'outils de diagnostic médical et la disponibilité de grandes quantités de données de haute qualité, il est devenu essentiel de développer des méthodes d'analyse de données plus avancées. Les méthodes traditionnelles ne sont pas en mesure de traiter de grandes quantités de données ou de découvrir des schémas dans celles-ci.

L'extraction des caractéristiques à l'aide de réseaux de neurones convolutionnels (CNN) et leur classification par des machines à vecteurs de support (SVM) sont deux techniques couramment utilisées dans le domaine de l'apprentissage automatique. L'extraction des caractéristiques par CNN consiste à faire passer une image à travers des couches convolutionnelles afin d'extraire des motifs et des traits significatifs, tels que les bords, les formes et les textures

présentes dans l'image. Les caractéristiques ainsi extraites par le CNN servent ensuite de représentation compacte de l'image.

Une fois les caractéristiques extraites, elles peuvent être utilisées comme entrée pour des algorithmes de classification, tels que le SVM. Le SVM est un modèle d'apprentissage supervisé qui vise à séparer les données en différentes classes.

Ce mémoire est organisé comme suit dans le premier chapitre on va présenter les principales techniques et algorithmes utilisés dans un système de vision par ordinateur. Les concepts fondamentaux du traitement d'images numériques et des techniques d'apprentissage automatique utilisées dont les applications de diagnostic de la leucémie aiguë sont également abordés.

Le deuxième chapitre est consacré à la description des réseaux de neurones convolutionnelles ainsi que leur intérêt dans le domaine de la classification des images

Dans le troisième chapitre, on va montrer la partie expérimentale de notre travail et on discute les différents résultats obtenus et à la fin on termine par une conclusion générale

Chapitre I

Apprentissage artificielle et la vision par ordinateur

I.1 Introduction

La vision artificielle est une technologie qui permet à une machine de voir et d'interpréter les images comme le ferait un être humain. Cependant, Le développement de la technologie d'analyse d'images par ordinateur remonte aux années 1950 et 1960, lorsque les scientifiques ont commencé à développer des méthodes et des techniques pour convertir des images en données numériques pouvant être manipulées.

Cette technologie rencontre encore des problèmes majeurs. Premièrement, la reconnaissance d'objets est souvent difficile pour les machines, surtout si l'objet est partiellement caché ou situé dans un environnement complexe. De plus, la vision artificielle peut être affectée par des facteurs tels que la lumière, l'ombre et l'éblouissement, qui peuvent altérer la qualité de l'image et la rendre plus difficile à reconnaître. Enfin, la vision artificielle peut être limitée par les capacités de traitement de l'ordinateur ou du système utilisé, ce qui peut ralentir le traitement des images et réduire la précision de la reconnaissance. Malgré ces défis, la vision artificielle continue de progresser et est de plus en plus utilisée dans divers domaines tels que la sécurité, la surveillance et l'automatisation industrielle et la médecine, l'imagerie et la reconnaissance faciale[5].

L'apport des techniques de traitement d'images et d'apprentissage automatique au domaine de la médecine s'est fait à travers les images médicales numérisées où de nombreux phénomènes peuvent être analysés et étudiés à l'aide de l'ordinateur. Les progrès exponentiels de la recherche et du développement dans le domaine de l'analyse d'images ont contribué de manière significative au domaine de la médecine. Les images médicales sont considérées comme un outil essentiel utilisé pour le diagnostic et l'analyse de nombreuses maladies. Le format numérique des images médicales offre la possibilité d'une analyse plus approfondie pouvant conduire à un diagnostic plus précis et donc une prise en charge optimisée du patient. Ces images peuvent également être utilisées à des fins de recherche et d'enseignement.

Les images médicales numériques utilisées dans ce travail sont des images microscopiques de cellule de sang . L'analyse des composants sanguins et de ses modifications est l'un des tests de diagnostic réguliers dans la clinique.

Le but de ce chapitre est de mettre en évidence les principales techniques et algorithmes utilisés dans un système de vision par ordinateur. Les concepts fondamentaux du traitement d'images numériques et des techniques d'apprentissage automatique utilisées dans les applications de diagnostic de la leucémie aiguë sont également abordés.

Avec le développement de diverses technologies et l'émergence de technologies modernes telles que l'apprentissage automatique et l'intelligence artificielle, la technologie d'analyse d'images par ordinateur est devenue plus efficace et précise et a été utilisée dans de nombreuses applications différentes.

I.2 Leucémie aiguë lymphoblastique

Le sang est un tissu conjonctif qui circule dans les vaisseaux sanguins des animaux qui ont un système circulatoire fermé. En hématologie, la branche de la médecine concernée par l'étude du sang, les modifications de la forme et de la fonction des leucocytes sont appelées anomalies leucocytaires, et la leucémie est l'une de ces anomalies. Les leucémies sont des cancers des globules blancs ou des cellules qui se développent en globules blancs.

Les globules blancs sont issus de la différenciation (ou maturation) progressive de cellules souches dans la moelle osseuse. La différenciation se déroule parfois de façon anormale et des parties de chromosomes font l'objet de réarrangements. Les chromosomes qui présentent ces anomalies perturbent la division cellulaire normale, de sorte que les cellules touchées se multiplient de manière incontrôlée ou deviennent résistantes à la mort cellulaire normale, ce qui est à l'origine de la leucémie.

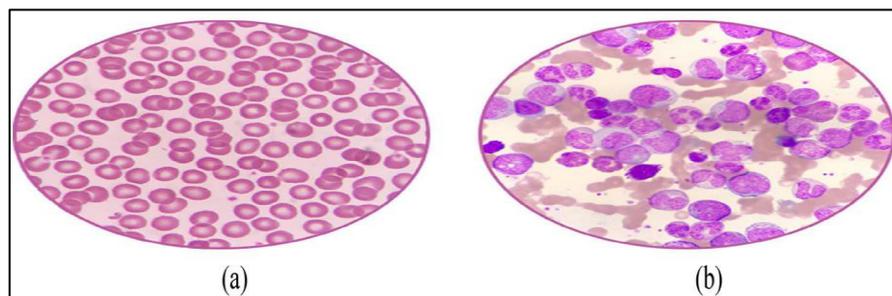


Figure I.1 : a) image sanguine normal. (b) image sanguine leucémiques

Les leucémies se divisent en quatre principaux types :

- La leucémie lymphoïde aiguë Acute lymphocytic leukemia (ALL)
- Leucémie myéloïde aiguë, Acute myelogenous leukemia (AML),
- La leucémie lymphoïde chronique n'xamely Chronic lymphocytic leukemia (CLL)
- Leucémie myéloïde chronique Chronic myelogenous leukemia (CML)

Ces types sont définis en fonction de la rapidité de leur évolution et des caractéristiques des globules blancs qui deviennent cancéreux [6].

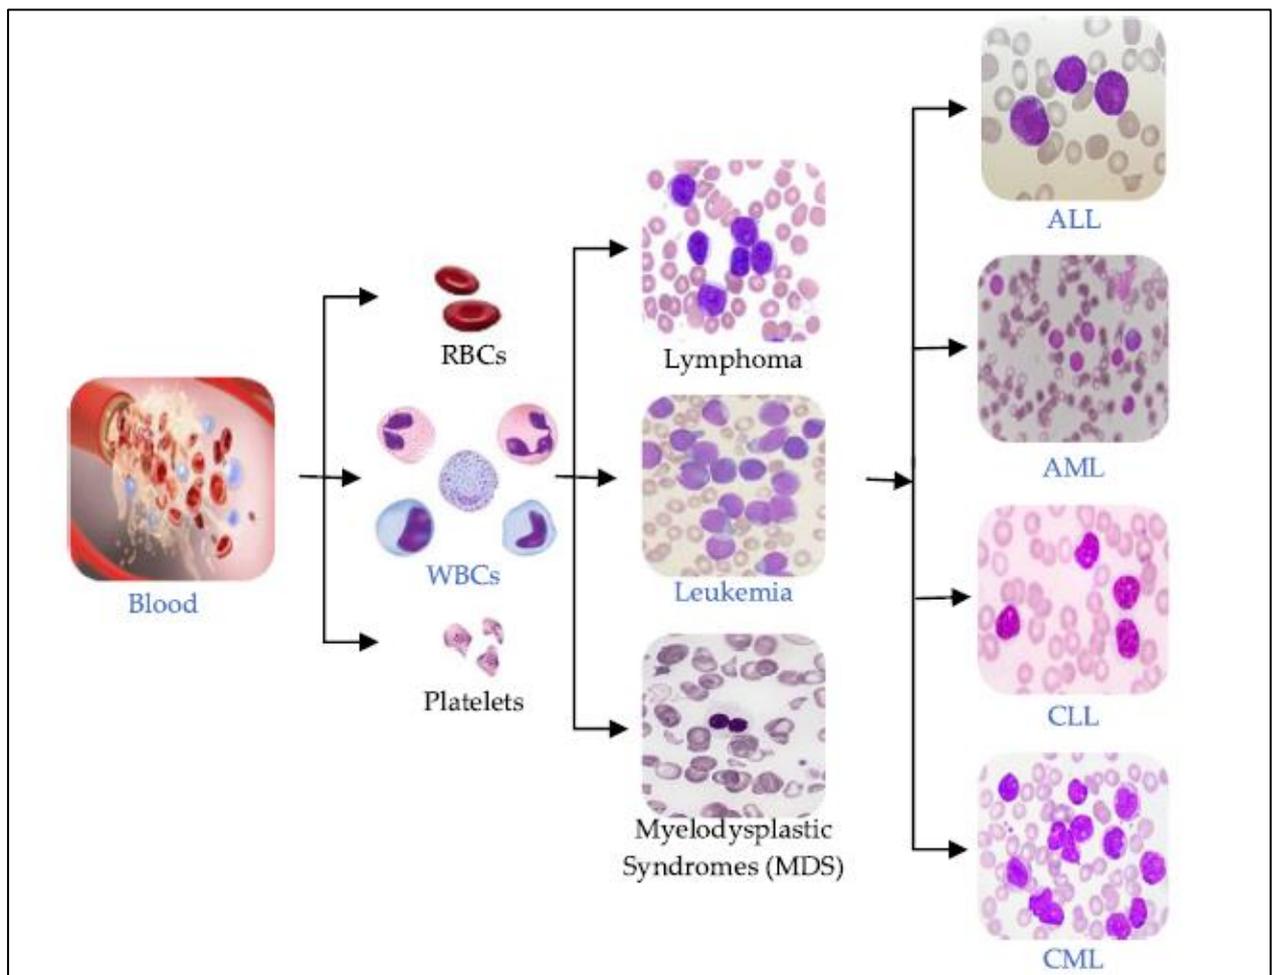


Figure I.2 : les composants du sang et les types de leucémies

- Les leucémies aiguës se caractérisent par un développement rapide, et présentent des cellules immatures.
- Les leucémies chroniques progressent lentement et présentent des cellules plus matures.
- Les leucémies lymphocytaires résultent de la transformation maligne de lymphocytes ou de cellules qui normalement produisent les lymphocytes. Elles peuvent être aiguës ou chroniques.
- Les leucémies myéloïdes (myélocytaires ou myélogènes) proviennent de la transformation maligne de cellules qui produisent normalement les neutrophiles, les basophiles, les éosinophiles et les monocytes. Elles peuvent être aiguës ou chroniques. Complications de la leucémie

La leucémie aiguë lymphoblastique ou acute lymphoblastic leukemia (ALL), objet principal de cette étude, survient lorsqu'un grand nombre de lymphoblastes s'accumulent dans la moelle osseuse et le sang périphérique. La ALL est la leucémie infantile la plus courante. La fréquence la plus élevée de ALL se situe chez les enfants entre 3 et 7 ans avec 75 % des diagnostics survenant avant l'âge de 6 ans. [7].

L'analyse microscopique manuelle d'échantillons de sang est la principale méthode d'analyse des lymphocytes extraits de patients atteints de leucémie. En conséquence, la classification des lymphocytes sains et malins dépend fortement de l'expertise des hématologues et des pathologistes dans la reconnaissance des deux classes.

Pour aider ces professionnels dans l'analyse de sang, des techniques de traitement d'image et de reconnaissance de formes ont été largement utilisées pour produire des systèmes de diagnostic assisté par ordinateur (CAD). Ces systèmes visent à augmenter la précision de la classification [8,9].

I.3 Représentation des images numériques de microscopie sanguine

L'image c'est une représentation visuelle ou bien un ensemble des points qui donne une certaine information, message, résultat, abstraction, objet, être vivant, idée, etc. Quant à la médecine, c'est l'un des moyens les plus importants, utilisés pour le diagnostic et la détection de certaines maladies telles que les images microscopiques du sang.

L'image numérique est définie comme une fonction bidimensionnelle $f(x,y)$ discrète où x et y sont des coordonnées spatiales. La valeur de f à n'importe quelle coordonnée (x,y) est appelée élément d'image (pixels). L'amplitude de chaque pixel représente l'intensité à ce pixel particulier. La résolution d'une image numérique est déterminée par le nombre de pixels dans l'image. En image numérique, la coordonnée spatiale $f(0,0)$ représente le coin supérieur gauche de l'image et la coordonnée spatiale $f(x - 1, y - 1)$ représente le coin inférieur droit. La figure I.3 montre un échantillon d'image microscopique du sang .

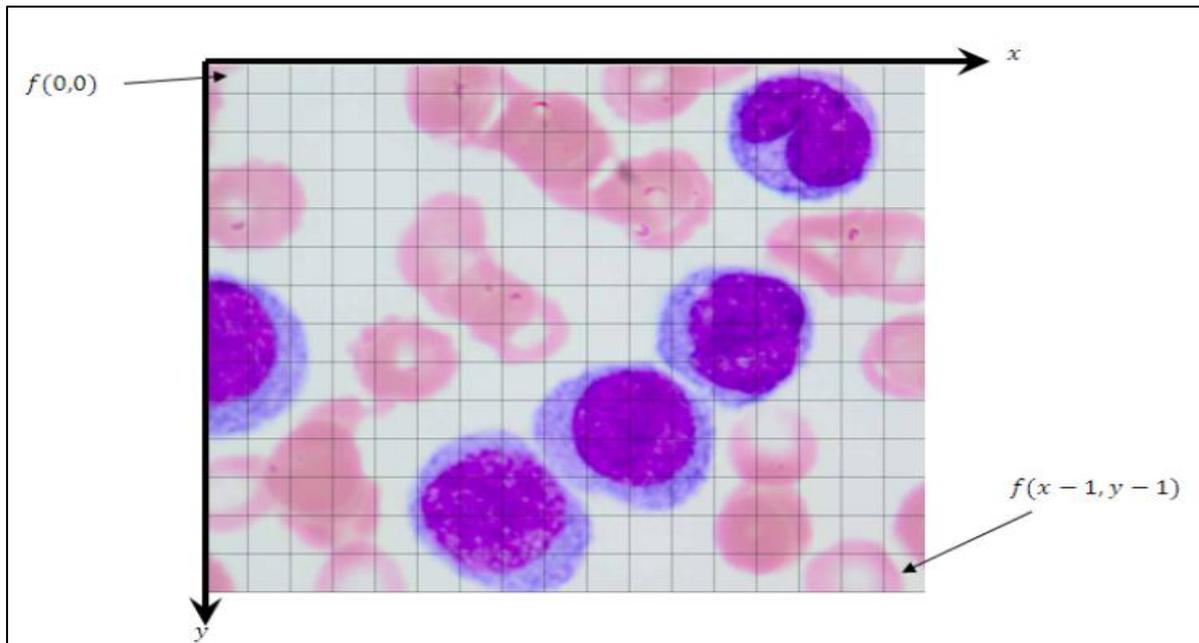


Figure I.3 : représentation de l'image numérique microscopique du sang

I.4 Les différents types d'image:

- **Image noir et blanc (binaire)**

Une image binaire est une matrice rectangulaire dont les éléments valent 0 ou 1. Lorsque l'on visualise une telle image, les zéros sont représentés par des noirs et les uns par des blancs [10], comme illustré la figure suivant

1	1	1	1	1	1	1	1	1	1
1	1	1	0	0	0	0	1	1	1
1	1	0	1	1	1	1	0	1	1
1	0	1	1	1	1	1	1	0	1
1	0	1	0	1	1	0	1	0	1
1	0	1	1	1	1	1	1	0	1
1	0	1	0	1	1	0	1	0	1
1	0	1	1	0	0	1	1	0	1
1	1	0	1	1	1	1	0	1	1
1	1	1	0	0	0	0	1	1	1
1	1	1	1	1	1	1	1	1	1

Figure I.4 : Exemple d'une image binaire.

- **Niveau de gris**

Dans une image en niveaux de gris (nuances de gris), la couleur d'un pixel peut prendre des valeurs allant du noir (0) au blanc (255) en passant par un nombre fini de niveaux intermédiaires obtenus par dégradation du noir [10]. Le pixel est ainsi codé sur un octet

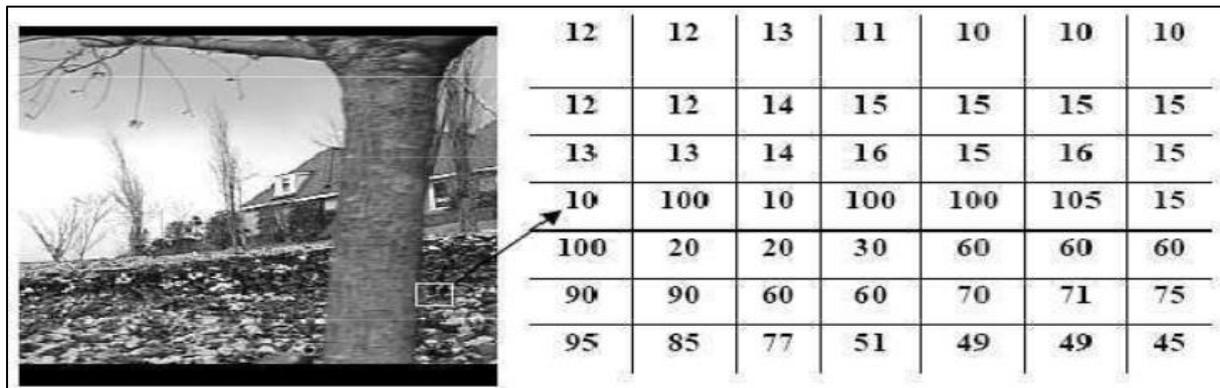


Figure I.5 : Exemple d'image en niveau de gris et sa quantification

- **Image couleur RVB :**

L'œil humain analyse les couleurs via des cellules photo réceptrices, et perçoit toute couleur comme une combinaison des 3 couleurs de base: rouge, vert, bleu, alors pour représenter la couleur d'un pixel, il est nécessaire de donner trois nombres qui correspondent au dosage des trois couleurs de base [10].

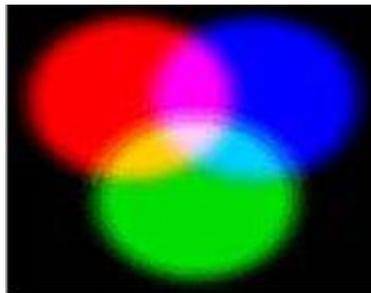


Figure I.6 : les couleurs Rouge Vert Bleu(RVB)

I.5 Système de vision par ordinateur

La vision artificielle ou vision assistée par ordinateur (V. A .O) symbolise toute la chaîne visuelle partant de l'image brute et allant jusqu'à l'interprétation de son contenu. Il existe donc un aspect décisionnel très important lors de la phase de compréhension, d'où l'interaction avec l'intelligence artificielle. Le traitement d'images s'intègre dans ce processus comme un outil, il n'a aucun pouvoir décisionnel car il se définit comme un ensemble de tâches destinées à extraire de l'image des informations qualitatives et quantitatives qui sont transmises au module de niveau supérieur [11].

Les étapes d'une chaîne de vision par ordinateur se résument dans la figure I.7 suivante :

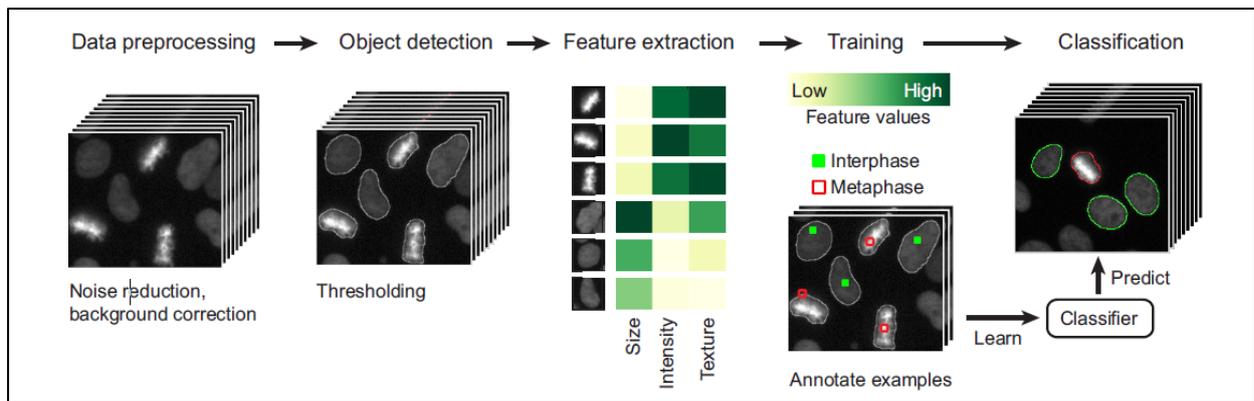


Figure I.7: Les étapes d'un système de vision par ordinateur

I.5.1 Prétraitements

Le rôle du prétraitement dans sa définition la plus générale est de remédier aux dégradations ayant affecté l'image et/ou de rendre cette image mieux adaptée à une application particulière

Le prétraitement des données consiste à traduire les données brutes sous une forme adaptée au modèle. C'est aussi une stratégie pour améliorer les performances du modèle en améliorant le signal d'intérêt par rapport au bruit de fond (figure I.8). Il existe un ensemble d'étapes générales de prétraitement. Ils incluent la normalisation des données, la mise à l'échelle des caractéristiques, la réduction de la dimensionnalité et la soustraction moyenne. D'autres stratégies sont spécifiques au problème traité. Dans l'analyse d'images microscopiques, cela peut inclure la correction d'un éclairage de scène inégal et des filtres de lissage pour réduire les artefacts de microscopie. Le contrôle qualité est une autre forme de prétraitement des données. Les exemples incluent la suppression des valeurs aberrantes ou des échantillons manquants [12].

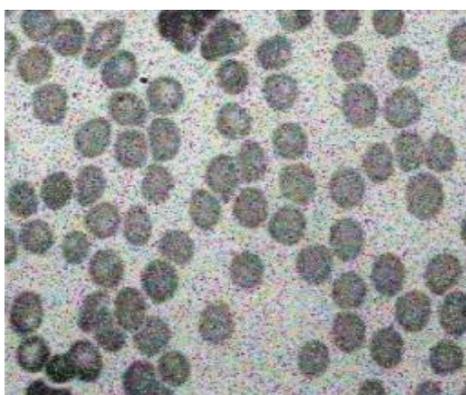


Image avec bruit

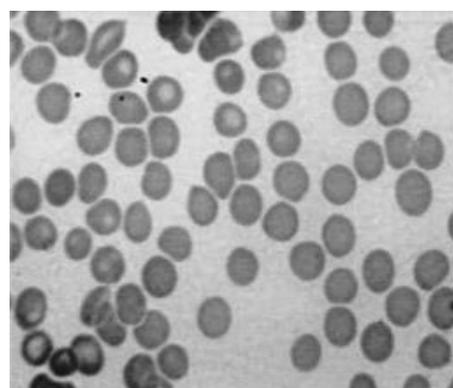


Image sans bruit

Figure I.8 : Image avec et sans bruit

I.5.2 La Segmentation

a) Définition

"La segmentation est un traitement de bas niveau qui consiste à créer une partition de l'image A en sous-ensembles R_i , appelés régions tels qu'aucune région ne soit vide, l'intersection entre deux régions soit vide et l'ensemble des régions recouvre toute l'image. Une région est un ensemble de pixels connexes ayant des propriétés communes qui les différencient des pixels des régions voisines" [13].

On peut dire que : La segmentation est la partition d'une image en un ensemble de régions qui ne se chevauchent pas et dont l'union est l'image entière. Quelques règles à suivre pour obtenir une segmentation sont [14]:

1. Les régions doivent être uniformes et homogènes par rapport à certaines caractéristiques (niveau de gris, écart type, gradient).
2. Leurs intérieurs doivent être simple et sans beaucoup de petits trous (des parties de région non segmentés).
3. Les régions adjacentes doivent avoir des valeurs très différentes par rapport à la caractéristique prise en compte dans la segmentation.
4. Les limites de chaque région doivent être simples et spatialement précises.

En termes mathématiques :

$$\left\{ \begin{array}{l} \bigcup_{i=1}^n R_i = I \\ R_i \neq \phi \forall i = 1 \dots n \\ R_i \cap R_j = \phi \forall i, j \text{ avec } i \neq j \end{array} \right.$$

Où R_i est l'ensemble des régions formant l'image I [15].

En imagerie WBC, la région d'intérêt peut être des globules blancs dans l'image microscopique du sang [16].

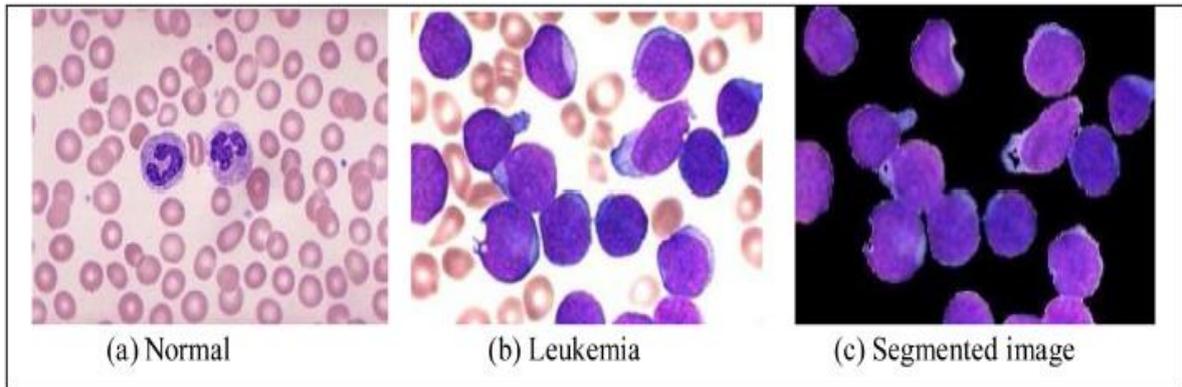


Figure I.9 : exemple de segmentation des images

La segmentation d'images comprend de nombreuses techniques telles que le seuillage (seuil d'Otsu, algorithme de Zack et méthode d'entropie maximale), la segmentation basée sur les régions (croissance des régions, division et fusion des régions), la segmentation des bassins versants, la segmentation basée sur le clustering. Segmentation (K-Means FCM, K- Medoids , ...etc).

L'une des étapes les plus importantes et difficiles dans le diagnostic et la classification de la leucémie aiguë est l'étape de segmentation car l'efficacité des deux prochaines étapes dépend entièrement de cette étape.

La taxonomie des méthodes de segmentation des globules blancs pour la leucémie aiguë et les globules blancs est illustrée dans la Figure I.10. la plupart des méthodes traditionnelles que nous avons examinées utilisaient la méthode de seuillage dans l'étape de segmentation. Nous détaillons cette méthode dans la suite [17].

b) Segmentation par seuillage :

Le seuillage représente un outil largement utilisé dans la segmentation d'image pour extraire des objets de leurs fonds en fonction d'un seuil. Tout problème de seuillage consiste alors à rechercher la valeur du seuil. La plupart des méthodes de seuillage déterminent le seuil en optimisant une fonction objective. On distingue le seuillage de base (simple) (2 classes) où le résultat du seuillage est une image binaire (0 : 1, parfois en 0 :255 pour l'affichage), et le multi-seuillage qui est utile quand on a affaire à des images qui contiennent plusieurs objets ayant des luminances différentes. Pour extraire ces objets, plusieurs seuils sont nécessaires.

Le résultat du seuillage est une image avec $n+1$ classes pour n seuils.

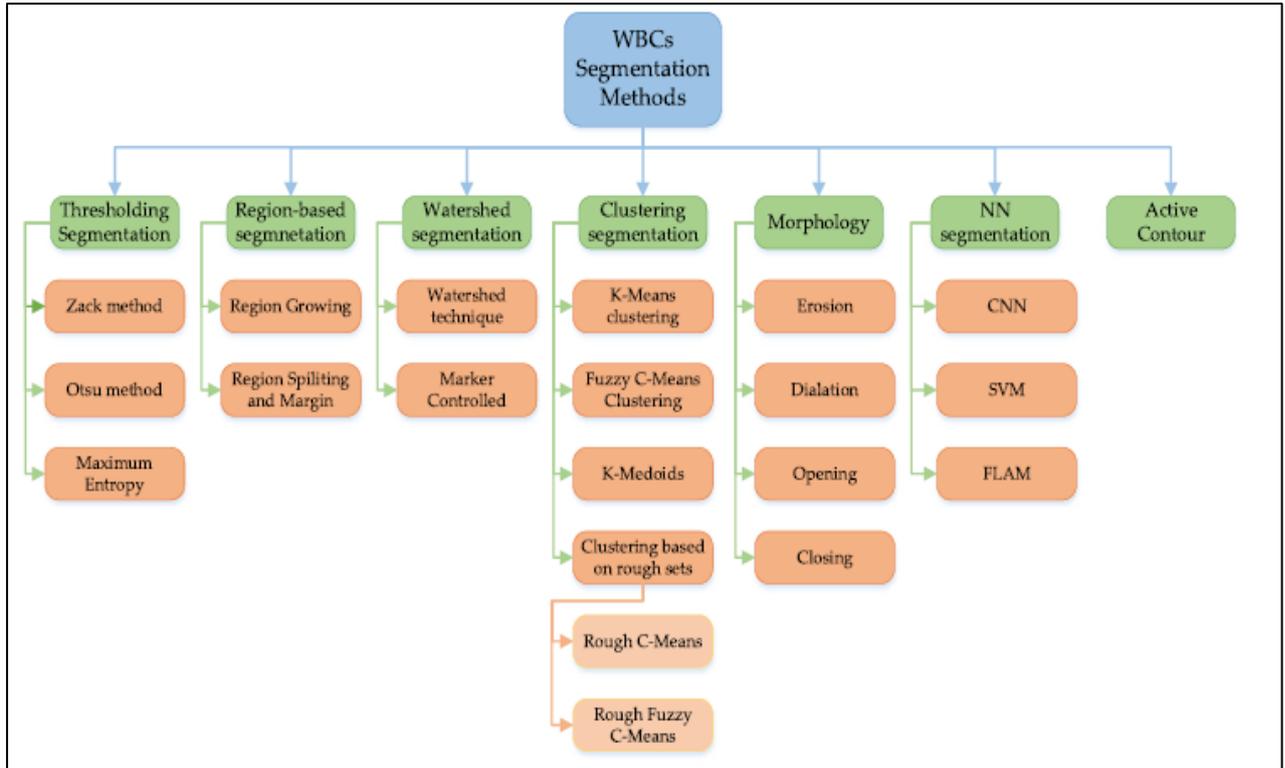
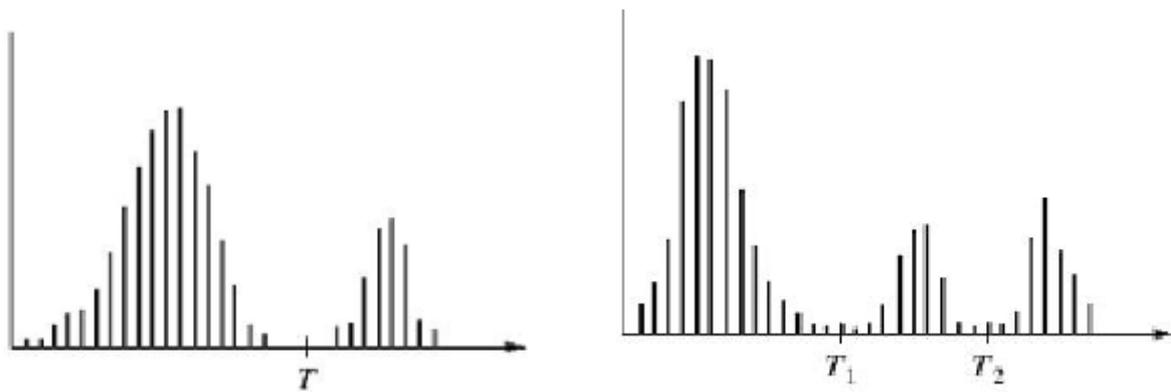


Figure I.10 : Méthodes de segmentation utilisées en WBC [13]



$$G(x, y) = \begin{cases} 1 & \text{si } f(x, y) \geq T \\ 0 & \text{si } f(x, y) < T \end{cases}$$

(a)

$$G(x, y) = \begin{cases} 2 & \text{si } f(x, y) \geq T_2 \\ 1 & \text{si } T_1 \leq f(x, y) < T_2 \\ 0 & \text{si } f(x, y) < T_1 \end{cases}$$

(b)

Figure I.11 : a) Seuillage simple d'un histogramme b) Seuillage multiple d'un histogramme.

La segmentation par seuillage d'histogramme constitue un cas particulier de la segmentation par classification. Elle permet de répartir les pixels en classes en fonction de leurs niveaux de gris. Les classes sont alors délimitées par des seuils [18].

c) La méthode d'Otsu

La méthode Otsu c'est une méthode globale de binarisation connue des années 1979[19] est utilisée pour effectuer un seuillage automatique à partir de la forme de l'histogramme de l'image. Cette méthode nécessite donc le calcul préalable de l'histogramme de l'image comme l'indique dans la formule 1 :

$$\text{Hist}(k) = \sum_{i=1}^n \sum_{j=1}^m (\text{image}(i, j) == k) \quad (\text{I.1})$$

La probabilité de chaque niveau de gris est indiqué dans la formule 2 :

$$P(k) = (\text{Hist}(k)) / (\text{Nombre total de pixels dans l'image}) \quad (\text{I.2})$$

L'image à binariser dans cette méthode ne contient que deux classes, (Les objets et l'arrière-plan). Donc trouve un seuil optimal T qui sépare ces deux classes afin que la variance intra-classe soit minimale et que la variance interclasse soit maximale de l'histogramme de l'image

Dans la méthode d'Otsu, le seuil qui minimise la variance intra-classe est recherché à partir de tous les seuillages possibles : la formule 3 représente comment calculer la variance intra classe

$$\sigma_w^2 = w_1 \times (t) \times \sigma_1^2(t) + w_2(t) \times \sigma_2^2(t) \quad (\text{I.3})$$

Les poids représentent la probabilité d'être dans la $i^{\text{ème}}$ classe, chacune étant séparée

par un seuil t finalement, les σ_i^2 sont les variances de ces classes.

Otsu montre que minimiser la variance intra-classe revient à maximiser la variance inter classe comment l'indique de la formule 4

$$\sigma_y^2 = \sigma^2 - \sigma_w^2 \quad (\text{I.4})$$

Qui est exprimée en termes des probabilités de classe et des moyennes de classes moy(t) qui à leur tour peuvent être mises à jour itérativement. Cette idée conduit à un algorithme efficace [19].

Les formules 5 et 6 représentent comment calculer la probabilité de classe 1 et 2

Les formules 7 et 8 représentent comment calculer la variance de chaque classe

$$w_1(t) = \sum_k^t p(k) \quad (I.5)$$

$$w_2(t) = \sum_{k=t+1}^{256} p(k) \quad (I.6)$$

$$\sigma_1^2(t) = \frac{\sum_{k=1}^t (N_1(i) - \text{moy}(t))^2}{w_1} \times p(i) \quad (I.7)$$

$$\sigma_2^2(t) = \frac{\sum_{i=t+1}^{256} (N_2(i) - \text{moy}_2(t))^2}{w_2} \times p(i) \quad (I.8)$$

- ✓ N1 est un vecteur de 0 à t-1 ;
- ✓ N2 est un vecteur de t à 255 ;
- ✓ Moy1 représente la moyenne de la classe 1 ;
- ✓ Moy2 représente la moyenne de la classe 2.

Les formules 9 et 10 calculent la moyenne de chaque classe :

$$\text{Moy}_1(t) = \frac{\sum_{i=1}^t N_1(i) \times p(i)}{w_1} \quad (I.9)$$

$$\text{Moy}_2(t) = \frac{\sum_{i=t+1}^{256} N_2(i) \times P(i)}{w_2(t)} \quad (I.10)$$

- ✓ N1 est un vecteur de 0 à t-1 ;
- ✓ N2 est un vecteur de t à 255 [19].

L'inconvénient de la méthode d'Otsu est qu'elle n'est applicable que lorsque l'image est bimodale (l'histogramme comporte deux pics).

I.5.3 Extraction des caractéristiques

Un problème majeur dans tout système de reconnaissance de formes est l'extraction de caractéristiques appropriées qui différencient efficacement les différentes formes. Au cours des dernières décennies, divers schémas d'extraction de caractéristiques ont été développés. Habituellement, dans l'extraction de caractéristiques, les informations visuelles d'une image sont

analysées afin de produire des caractéristiques telles que la forme, la texture et la couleur, comme résumé dans la figure I.12

Il est largement admis qu'il n'existe pas des caractéristiques générales adaptées à différentes applications. La détermination des caractéristiques les plus efficaces dépend bien sûr directement de l'application et du problème étudié. Néanmoins, pour améliorer la précision de la classification, une ou plusieurs caractéristiques sont souvent combinées [20].

Pour le problème du diagnostic et de la classification de la leucémie aiguë, la leucémie aiguë est classée en deux types principaux (ALL et HEM). Trouver une mesure quantitative qui peut imiter les caractéristiques visuelles utilisées par l'hématologue pour distinguer les deux types n'est pas simple. Cela nécessite l'utilisation de divers types de caractéristiques telles que la forme, la texture et la couleur.

Cependant, il convient de mentionner que l'utilité de divers ensembles de caractéristiques ne peut être évaluée sans tenir compte de l'ensemble du système, par conséquent, il est nécessaire d'essayer différents types de caractéristiques qui semblent être proches de celles que les experts humains choisiraient et faire sélectionner le meilleur ensemble de caractéristiques basées sur l'évaluation des performances au niveau du système.

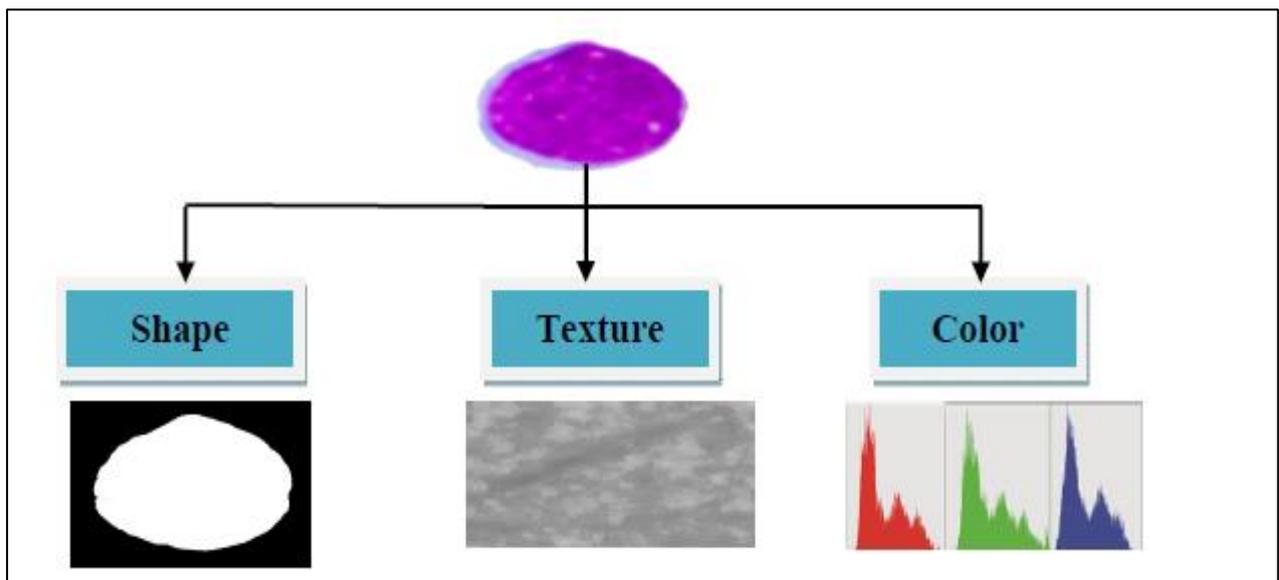


Figure I.12 : description des caractéristiques de l'image

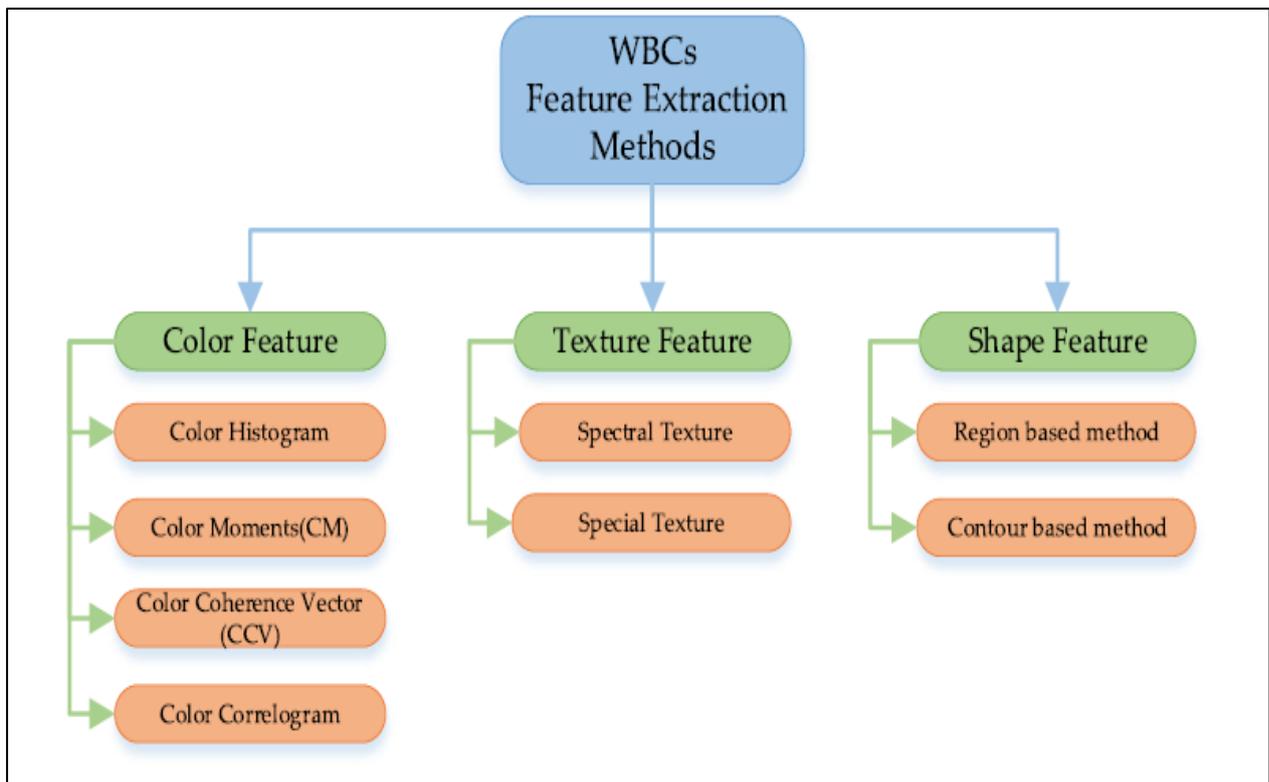


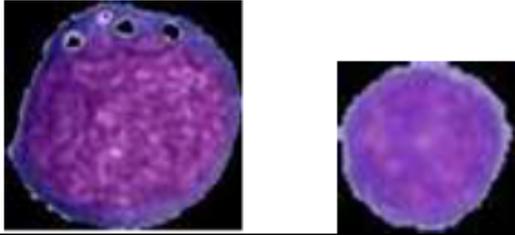
Figure I.13 : méthode d'extraction de caractéristique pour les images microscopique sanguines

[17]

I.5.3.1 Les caractéristiques de forme

La forme est une caractéristique visuelle importante ; il est considéré comme l'une des caractéristiques fondamentales de la reconnaissance d'objets. Cependant, la description de la forme est une tâche très difficile, car il est difficile de définir des caractéristiques de forme pertinentes et de mesurer la similitude entre des formes similaires.

De plus, la forme est souvent affectée par le bruit, la défection et l'occlusion. Les techniques de représentation et de description de forme sont divisées en deux grandes catégories, à savoir la représentation basée sur les frontières et la représentation basée sur les régions. La figure I.14



Features	Cancerous 7	Normal 42
Area	2089.5	1056
Perimeter	407.79	280.98
Compactness	80.26	74.76
Convex Area	6175	2137
Solidity	0.657	0.494
Eccentricity	0.442	0.439
Elongation	123.06	100
Form Factor	64.35	47.20
Contrast	0.668	1.362
Correlation	0.756	0.634
Homogeneity	0.839	0.810
Energy	0.159	0.192
Entropy	2.237	2.069
Mean	221.26	35.21
Standard Deviation	750.99	128.99
HausDroff	1.934	1.808

Figure I.14 : La différence entre la cellule normale et cellule cancéreuse [21]

I.5.3.2 Les caractéristiques de textures

Les techniques d'extraction de caractéristiques de texture sont divisé en quatre catégories principales, à savoir : structurelle, à base de modèle, à base de filtrage et statistique [21].

Pour capturer les informations cruciales de l'arrangement structurel du noyau et de la cellule entière, des mesures statistiques sont indispensables.

Les méthodes basées sur les statistiques représentent indirectement la texture par les propriétés non déterministes qui régissent la distribution et la relation entre les niveaux de gris d'une image. En calculant les caractéristiques locales à chaque point de l'image et en dérivant un ensemble de statistiques à partir de la distribution des caractéristiques locales, des méthodes statistiques peuvent être utilisées pour analyser la distribution spatiale des valeurs de gris.

Sur la base du nombre de pixels définissant la caractéristique locale, les méthodes statistiques peuvent être classées en statistiques de premier ordre (un pixel), de second ordre (paire de pixels) et d'ordre supérieur (trois pixels ou plus). Les statistiques estiment les propriétés de deux valeurs de pixel ou plus survenant à des endroits précis les uns par rapport aux autres.

Un exemple de l'utilisation des caractéristiques statistiques GLCM (grey level co-occurrence matrix) est représenté sur la figure I.15 [22]

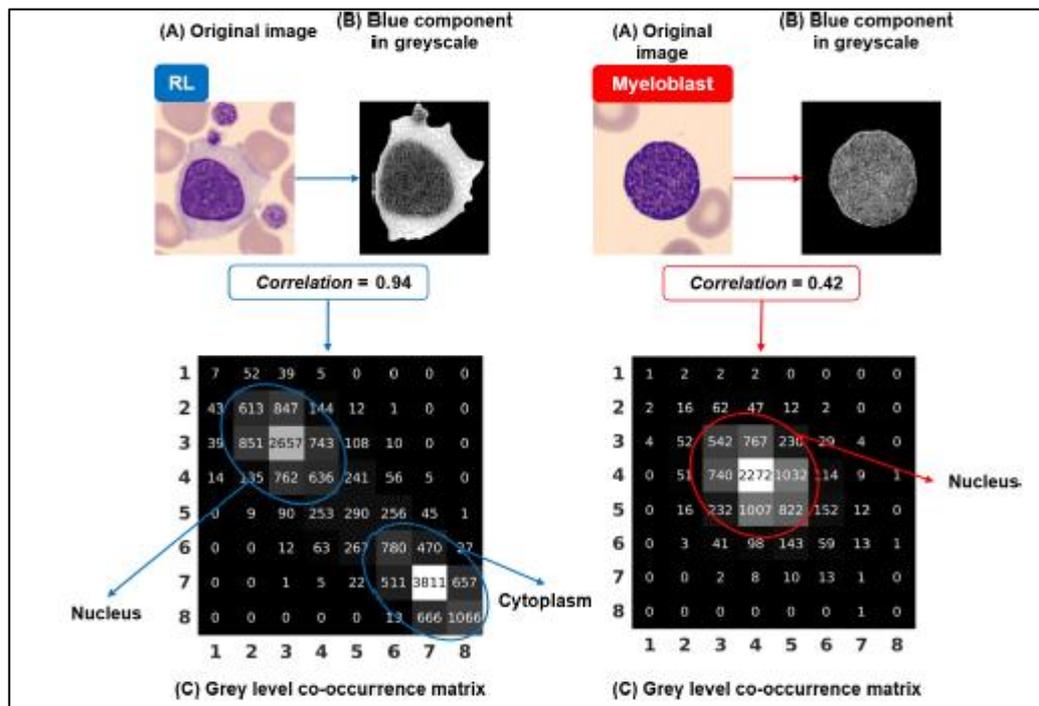


Figure I.15 : Exemple de l'utilisation des caractéristiques statistiques GLCM

I.6 Apprentissage automatique

L'apprentissage automatique, également appelé apprentissage machine ou apprentissage artificiel et en anglais machine Learning, est une forme d'intelligence artificielle (IA) qui permet à un système d'apprendre à partir des données et non à l'aide d'une programmation explicite. Cependant, l'apprentissage automatique n'est pas un processus simple. Au fur et à mesure que les algorithmes ingèrent les données de formation, il devient possible de créer des modèles plus précis basés sur ces données. Un modèle de machine Learning est le résultat généré lorsque vous entraînez votre algorithme d'apprentissage automatique avec des données. Après la formation, lorsque vous fournissez des données en entrée à un modèle, vous recevez un résultat en sortie. Par exemple, un algorithme prédictif crée un modèle prédictif. Ensuite, lorsque vous fournissez des

données au modèle prédictif, vous recevez une prévision qui est déterminée par les données qui ont servi à former le modèle.

Des techniques d'apprentissage automatique sont nécessaires pour améliorer l'exactitude des modèles prédictifs. Selon la nature du problème métier traité, il existe différentes approches qui varient selon le type et le volume des données. Dans cette section, nous discutons des catégories de l'apprentissage automatique .

La définition du machine Learning évolue depuis plusieurs années, et cela est dû au fait qu'à chaque fois il y a de nouvelles découvertes dans ce domaine : Le terme "apprentissage automatique" a été inventé par l'informaticien américain Arthur Samuel au début de 1959. Il a créé le premier programme Il permet aux ordinateurs de jouer et d'apprendre les dames sans être explicitement programmés

En 1997, l'informaticien américain Tom Michael Mitchell a introduit une nouvelle définition de l'apprentissage automatique. Il considère que le programme apprend de l'expérience E , comparée à une classe de tâches T , et à une mesure de performance P

Au fil du temps, la définition de l'apprentissage automatique a commencé à prendre une dimension mathématique et statistique [23].

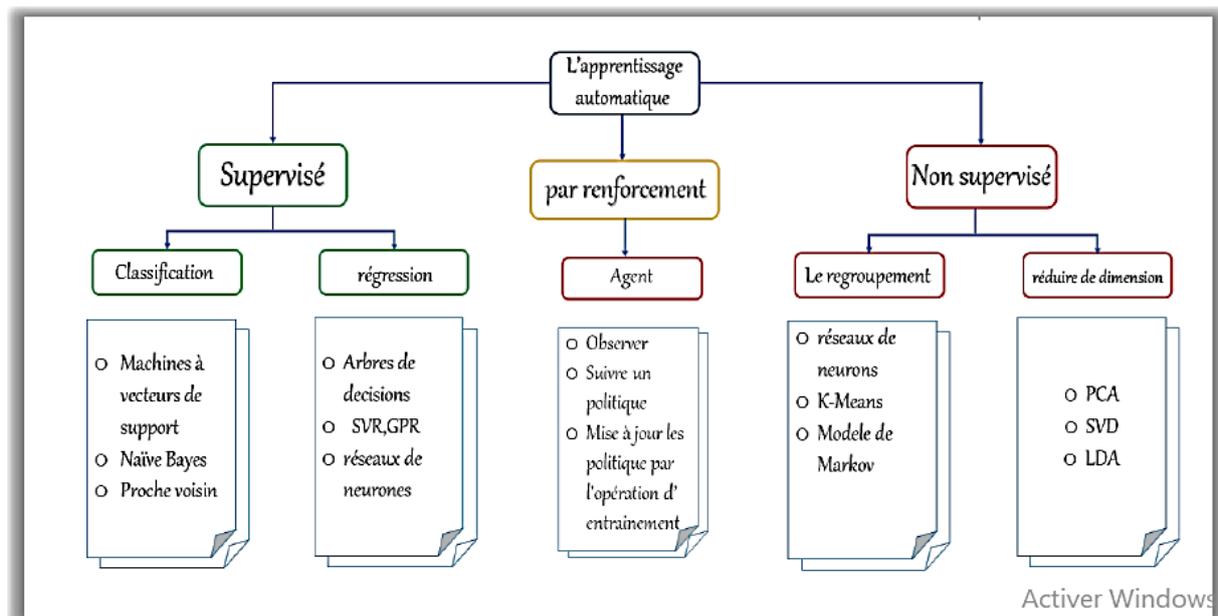


Figure I.16: Les approches et les algorithmes de l'apprentissage automatique [25]

a) Apprentissage supervisé

L'apprentissage supervisé, dans le contexte de l'intelligence artificielle (IA) et de l'apprentissage automatique, est un système qui fournit à la fois les données en entrée et les données attendues en sortie. Les données en entrée et en sortie sont étiquetées en vue de leur classification, afin d'établir une base d'apprentissage pour le traitement ultérieur des données.

Les systèmes d'apprentissage automatique supervisé alimentent les algorithmes d'apprentissage avec des quantités connues qui étayeront les futures décisions.

Les données utilisées pour l'apprentissage supervisé sont une série d'exemples comprenant des paires composées de sujets en entrée et de sorties attendues (appelées également signaux de supervision). Prenons l'exemple d'un système d'apprentissage supervisé pour le traitement d'images dans lequel on introduit des photos de véhicules appartenant aux catégories voitures et camions. Après un temps d'observation suffisant, le système doit être capable de faire la distinction entre plusieurs images non étiquetées et de les catégoriser ; une fois cet objectif atteint, l'apprentissage peut être considéré comme terminé [24].

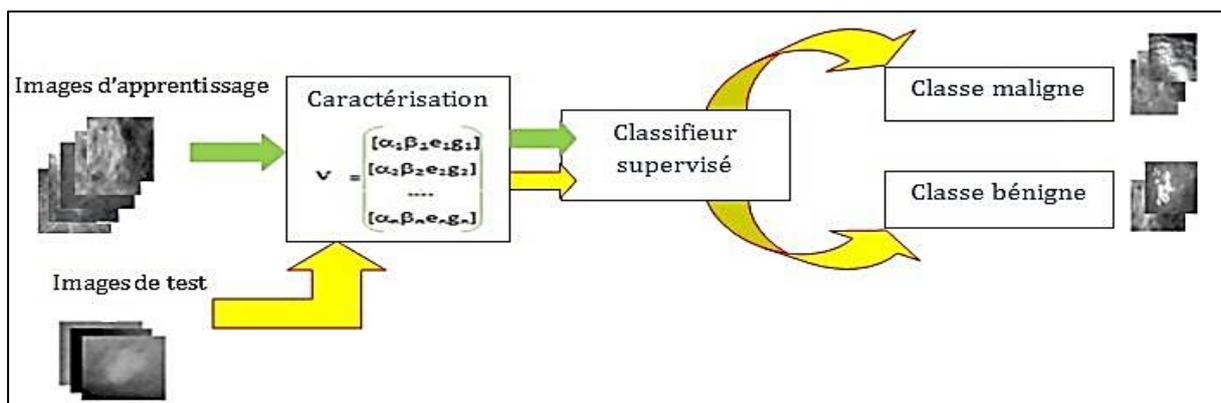


Figure I.17 : L'apprentissage supervisé

b) Apprentissage non supervisé

L'apprentissage supervisé, dans le contexte de l'intelligence artificielle (IA) et de l'apprentissage automatique, est un système qui fournit à la fois les données en entrée et les données attendues en sortie. Les données en entrée et en sortie sont étiquetées en vue de leur classification, afin d'établir une base d'apprentissage pour le traitement ultérieur des données.

Les systèmes d'apprentissage automatique supervisé alimentent les algorithmes d'apprentissage avec des quantités connues qui étayeront les futures décisions.

Les données utilisées pour l'apprentissage supervisé sont une série d'exemples comprenant des paires composées de sujets en entrée et de sorties attendues (appelées également signaux de supervision). Prenons l'exemple d'un système d'apprentissage supervisé pour le traitement d'images dans lequel on introduit des photos de véhicules appartenant aux catégories voitures et camions. Après un temps d'observation suffisant, le système doit être capable de faire la distinction entre plusieurs images non étiquetées et de les catégoriser ; une fois cet objectif atteint, l'apprentissage peut être considéré comme terminé [25].

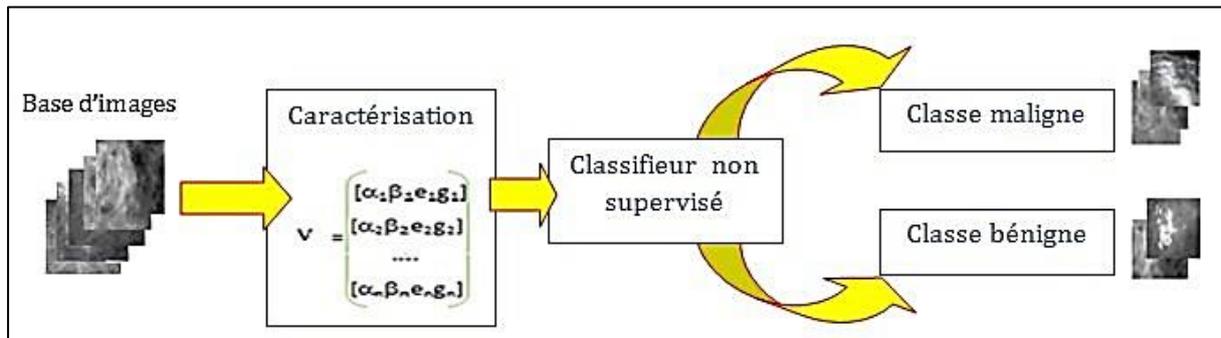


Figure I.18 : L'apprentissage non supervisé

c) Apprentissage par renforcement

L'apprentissage par renforcement (RL pour Reinforcement Learning) fait référence à une classe de problèmes d'apprentissage automatique, dont le but est d'apprendre, à partir d'expériences successives, ce qu'il convient de faire de façon à trouver la meilleure solution.

Dans un tel problème, on dit qu'un « agent » (l'algorithme, au sens du code et des variables qu'il utilise) interagit avec « l'environnement » pour trouver la solution optimale. L'apprentissage par renforcement diffère fondamentalement des problèmes supervisés et non supervisés par ce côté interactif et itératif : l'agent essaie plusieurs solutions (on parle « d'exploration »), observe la réaction de l'environnement et adapte son comportement (les variables) pour trouver la meilleure stratégie (il « exploite » le résultat de ses explorations). Un des concepts clés de ce type de problèmes est l'équilibre entre ces phases d'exploration et d'exploitation. Cette méthode est particulièrement adaptée aux problèmes nécessitant un compromis entre la quête de récompenses à court terme et celle de récompenses à long terme. Parmi les exemples de problèmes traités de cette façon, on peut évoquer : apprendre à un robot à marcher en terrain difficile, à conduire (cas de la voiture autonome) ou à accomplir une tâche spécifique (comme jouer au jeu de go), piloter un agent à travers un labyrinthe, etc. Les principales familles de problèmes d'apprentissage par

renforcement sont les algorithmes de bandits, les problèmes de décisions (partiellement) markovien et les arbres de jeu [26].

I.7 La classification

La classification est le processus qui consiste à reconnaître, à comprendre et à regrouper des idées et des objets dans des catégories prédéfinies ou des "sous-populations". À l'aide d'ensembles de données de formation pré-catégorisés, les programmes d'apprentissage automatique utilisent une variété d'algorithmes pour classer les futurs ensembles de données dans des catégories.

Les algorithmes de classification de l'apprentissage automatique utilisent des données d'apprentissage en entrée pour prédire la probabilité que les données suivantes entrent dans l'une des catégories prédéterminées. L'un des utilisations les plus courantes de la classification est la filtration d'images médicales pour des échantillons de sang malades ou non malades [27].

I.7.1 Présentation de certaines techniques de la classification

a) K-voisins les plus proches

Parmi les classificateurs d'images, KNN est le plus simple à comprendre et à mettre en œuvre. Ce la est dû au fait qu'un KNN ne fait aucun apprentissage. Au lieu de cela, une image de test est comparée à toutes les images dans l'ensemble de données étiqueté. Les images les plus similaires à l'image de test servent à un simple vote de majorité pour l'étiquette prédite de l'image de test.

Pour comparer l'image de test à une image d'entraînement, les deux vecteurs de caractéristique de chacune I_t et le respectivement sont utilisés pour calculer une distance qui peut être Euclidienne qui traduit la différence entre les deux images.

Les k images de distance minimale par rapport à l'image de test sont les voisins les plus proches de l'image de test. KNN est le plus approprié pour les problèmes de faible dimension. Dans la classification d'images, les performances KNN servent de référence pour les autres classificateurs.

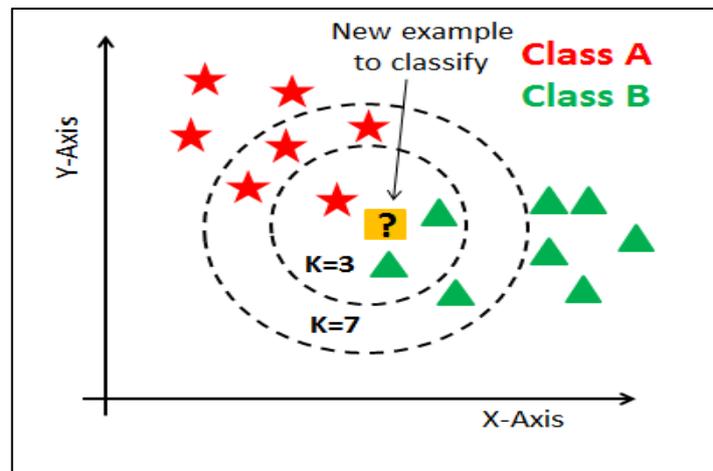


Figure I.19: Méthode de KNN.

b) Machines à vecteurs de support

Introduit par Vapnik en 1990, les machines à vecteurs de support sont des techniques d'apprentissage supervisé destinées à résoudre des problèmes de classification et de régression. Elles reposent sur deux notions principales : la notion de marge maximale et la notion de fonction noyau.[24, 25]

Les machines à support de vecteurs peuvent être utilisées pour résoudre divers problèmes en bio-informatique, recherche d'information et vision par ordinateur, etc.[29].

- **Le principe des SVM :**

Le but des SVM est de trouver un séparateur entre deux classes qui soit au maximum éloigné de n'importe quel point des données d'entraînement. Si on arrive à trouver un séparateur linéaire c'est-à-dire qu'il existe un hyperplan séparateur alors le problème est dit linéairement séparable sinon il n'est pas linéairement séparable et il n'existe pas un hyperplan séparateur [28, 29].

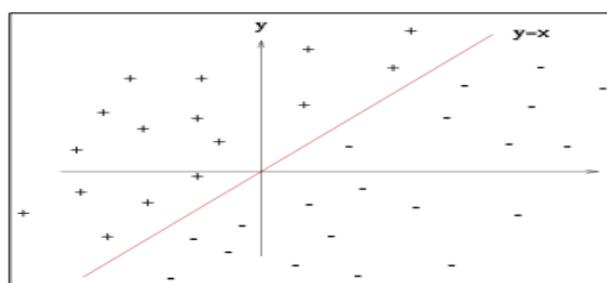


Figure I.20 : Problème de classification à deux classes avec une séparatrice linéaire [28].

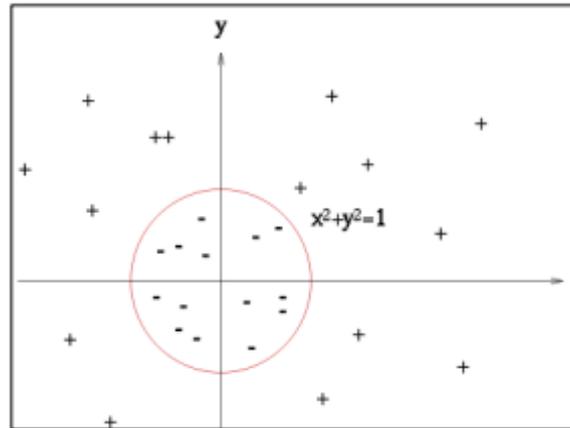


Figure I.21 : Problème de classification à deux classes avec une séparatrice non linéaire [28]

Pour deux classes et des données linéairement séparables (figure I.22), il y a beaucoup de séparateurs linéaires possibles. Les SVM choisissent seulement celui qui est optimal, c'est-à-dire la recherche d'une surface de décision qui soit éloignée au maximum de tout point de données. Cette distance de la surface de décision au point de données le plus proche détermine la marge maximale du classifieur. En effet, pour obtenir un hyperplan optimal, il faut maximiser la marge entre les données et l'hyperplan. [29].

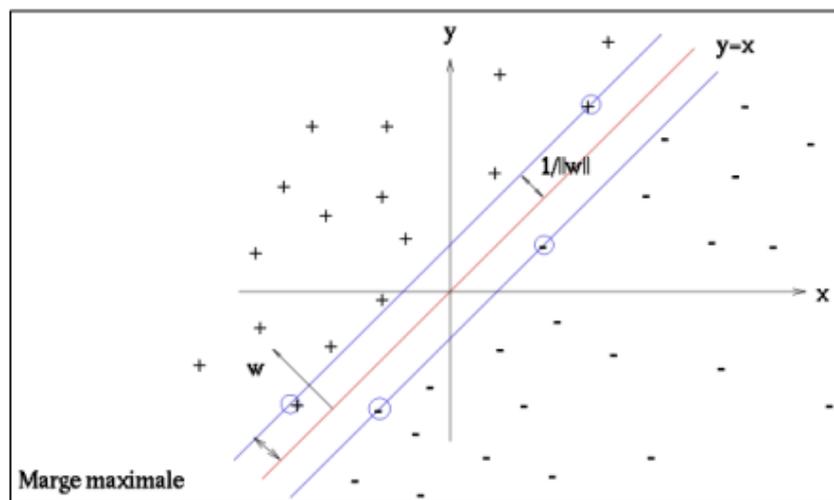


Figure I.22 : Hyperplan optimal avec une marge maximale [28]

Pour résoudre le problème de la non linéarité séparatrice, l'idée des SVM est d'augmenter la dimension d'espace de données. Dans ce cas, il est alors probable qu'il existe un séparateur

linéaire. En effet, la chance de trouver un hyperplan séparateur augmente proportionnellement avec la dimension d'espace de données. [28, 29]

Ce redimensionnement d'espace est basé sur l'utilisation de la fonction Kernel (noyau). On trouve plusieurs types de fonction noyau comme Gaussien, polynomiale et sigmoïde [28].

I.7.2 Evaluation de la Classification

I.7.2.1 Matrice de confusion :

La matrice de confusion appelée aussi matrice d'erreur, permet de mesurer la qualité du système de classification utilisé. Son rôle principal c'est d'effectuer plus rapidement une analyse approfondie des statistiques et aussi faciliter la lecture des résultats grâce à une visualisation claire des données. Elle est appliquée dans plusieurs applications de l'intelligence artificielle comme: les statistiques, le data mining, les modèles d'apprentissage automatique... Un des intérêts de la matrice de confusion est qu'elle montre rapidement si un système de classification parvient à classifier correctement ou non [30].

Une matrice de confusion est utilisée pour avoir une image complète de la performance d'un modèle. Elle est définie de la manière suivante :

		Classe prédite	
		+	-
Classe vraie	+	TP True Positives	FN False Negatives Type II error
	-	FP False Positives Type I error	TN True Negatives

Figure I.23 : Exemple de la matrice de confusion.

- **Indicateurs principaux**

Les indicateurs suivants sont communément utilisés pour évaluer la performance des modèles de classification :

Indicateur	Formule	Interprétation
Accuracy	$\frac{TP + TN}{TP + TN + FP + FN}$	Performance globale du modèle
Précision	$\frac{TP}{TP + FP}$	À quel point les prédictions positives sont précises
Rappel Sensibilité	$\frac{TP}{TP + FN}$	Couverture des observations vraiment positives
Spécificité	$\frac{TN}{TN + FP}$	Couverture des observations vraiment négatives
F-mesure	$\frac{2TP}{2TP + FP + FN}$	Indicateur hybride utilisé pour les classes non-balancées

Figure I.24 : Indicateurs principaux.

I.7.2.2 Courbe ROC (Received Operating Characteristic)

La courbe ROC consiste à un graphique qui représente l'ensemble de performances d'un modèle de classification pour tous les seuils de la classification. Cette courbe trace le taux de vrais positifs en fonction du taux de faux positifs.

Avec cet outil on peut avoir toutes les informations sur la performance du classifieur et cela en utilisant l'aire sous la courbe. Plus elle se rapproche de 1, plus le classifieur est performant [30].

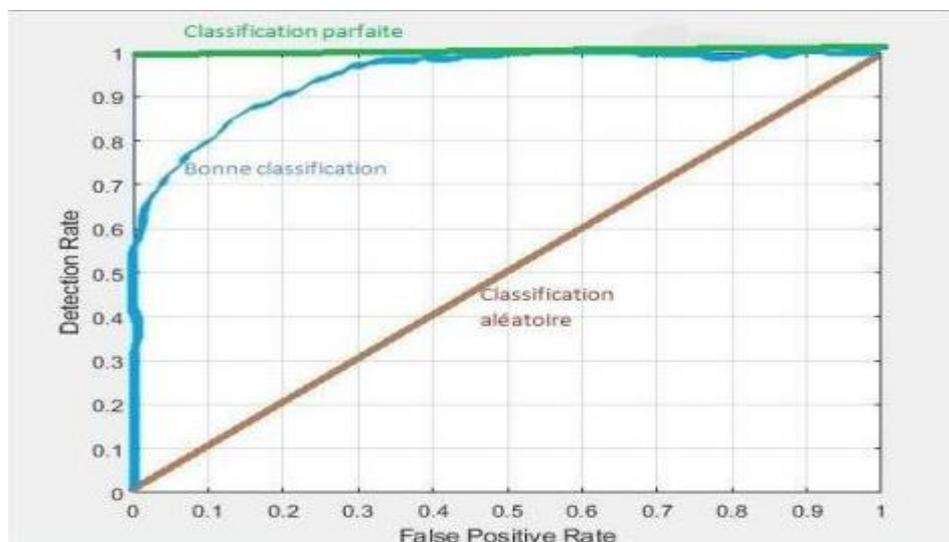


Figure I.25: Exemple d'illustration de la courbe ROC.

L'aire sous la courbe ROC, aussi notée AUC (de l'anglais Area Under the Curve) ou AUROC (de l'anglais Area Under the ROC), est l'aire sous la courbe ROC comme le montre la figure suivante:

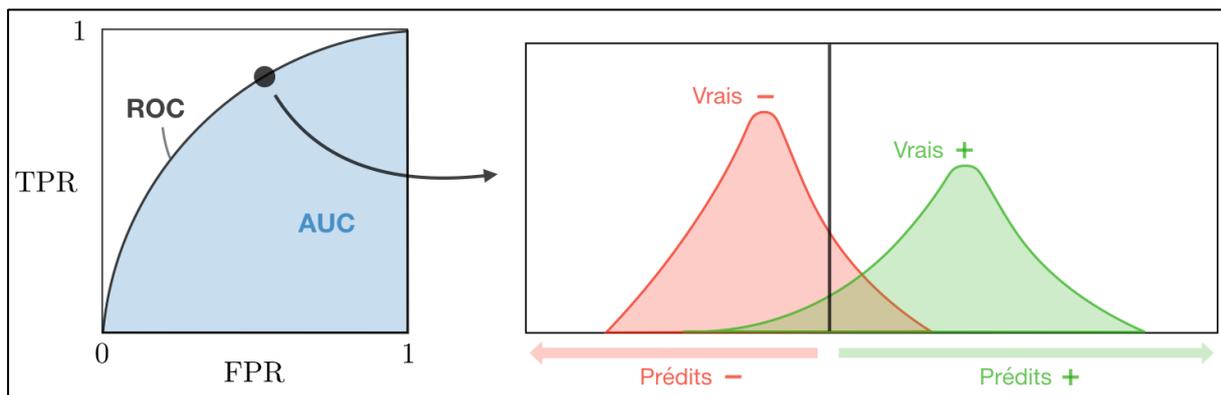


Figure I.26 : prédite négatif et positif de AUC.

I.8 Conclusion

Nous avons présenté dans ce chapitre la chaîne de vision par ordinateur dont le but est l'identification des cellules balistiques de la leucémie aiguë en partant des informations sur les images microscopiques sanguines, le prétraitement, la segmentation, l'extraction des différentes caractéristiques de forme ou de textures et arrivant aux techniques d'apprentissage automatique y compris les modes d'évaluation.

Les défis de la détection automatique sont associés à la nature complexe des globules blancs, y compris les limites irrégulières et les similitudes de texture entre les globules blancs et d'autres composants sanguins, qui entraînent des difficultés à séparer les cellules cancéreuses et les cellules saines. Au lieu d'utiliser des techniques traditionnelles d'apprentissage qui nécessitent du temps et des efforts, nous avons choisis des méthodes qui ont la capacité d'apprendre automatiquement à partir de données brutes. Ces méthodes sont appelées réseaux de neurones convolutionnels (convolutional neural network CNN) qui seront l'objet du chapitre prochain.

Chapitre II

*Réseaux de neurones
convolutionnels*

II.1 Introduction

La classification automatique des images de globules blancs sains et malins présente une valeur clinique élevée dans le diagnostic et le traitement précoce de la leucémie ALL. Cependant, le problème est difficile en raison de plusieurs complications. Premièrement, les cellules malignes présentent des caractéristiques morphologiques similaires aux cellules saines. Deuxièmement, la variation interclasse est difficile à modéliser avec une méthode d'apprentissage automatique traditionnelle. Avec les progrès récents de la vision par ordinateur et de l'apprentissage en profondeur deep Learning, une attention massive a été portée à l'application des réseaux de neurones convolutifs (CNN) en imagerie médicale. Dans ce chapitre nous allons présenter les notions en relation avec l'apprentissage profond.

II.2 l'apprentissage automatique (machine Learning) à l'apprentissage profond (Deep Learning)

L'apprentissage profond « Deep Learning » est un type d'intelligence artificielle dérivé de l'apprentissage automatique (machine Learning) ou la machine est capable d'apprendre et de s'améliorer par elle-même selon le nombre de données [31].

Les progrès de l'apprentissage profond ont été possibles notamment grâce à l'augmentation de la puissance des ordinateurs et au développement de grandes bases de données [32].

La figure suivante montre la relation entre les 3 concepts cités : Intelligence artificielle (AI), Machine Learning (ML) et Deep Learning (DL)

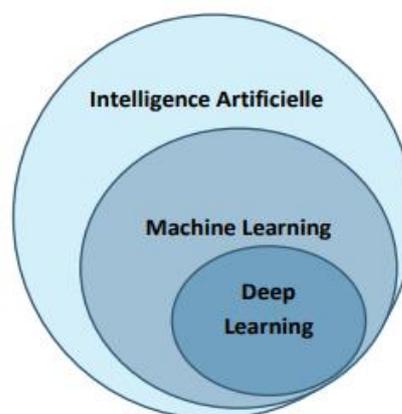


Figure II.1 : La relation entre l'IA, ML et le Deep Learning

Dans les algorithmes traditionnels de machine Learning, la notion de features (caractéristiques) en vision sont utilisées pour faire de la classification d'images. Ces méthodes consistent à extraire les features de chaque image du jeu de données manuellement par un expert, puis à entraîner un classifieur sur ces features. Ces techniques d'apprentissage supervisé peuvent fournir de très bons résultats, et leur performance dépend fortement de la qualité des features préalablement trouvées. figure II.2

Mais en 2012, une révolution se produit : lors de la compétition annuelle de vision par ordinateur ILSVRC, un nouvel algorithme de Deep Learning explose les records ! Il s'agit d'un réseau de neurones convolutif CNN. Les réseaux de neurones convolutifs ont une méthodologie similaire à celle des méthodes traditionnelles d'apprentissage supervisé : ils reçoivent des images en entrée, détectent les features automatiquement de chacune d'entre elles, puis entraînent un classifieur dessus. Donc les CNN réalisent eux-mêmes tout le boulot fastidieux d'extraction et description de features.

Lors de la phase d'entraînement, l'erreur de classification est minimisée afin d'optimiser les paramètres du classifieur et les features ! De plus, l'architecture spécifique du réseau permet d'extraire des features de différentes complexités, des plus simples au plus sophistiquées. L'extraction et la hiérarchisation automatiques des features, qui s'adaptent au problème donné, constituent une des forces des réseaux de neurones convolutifs. Aujourd'hui, les réseaux de neurones convolutifs, aussi appelés CNN ou ConvNet pour Convolutional Neural Network, sont toujours les modèles les plus performants pour la classification d'images. Cette partie leur est donc naturellement consacrée.

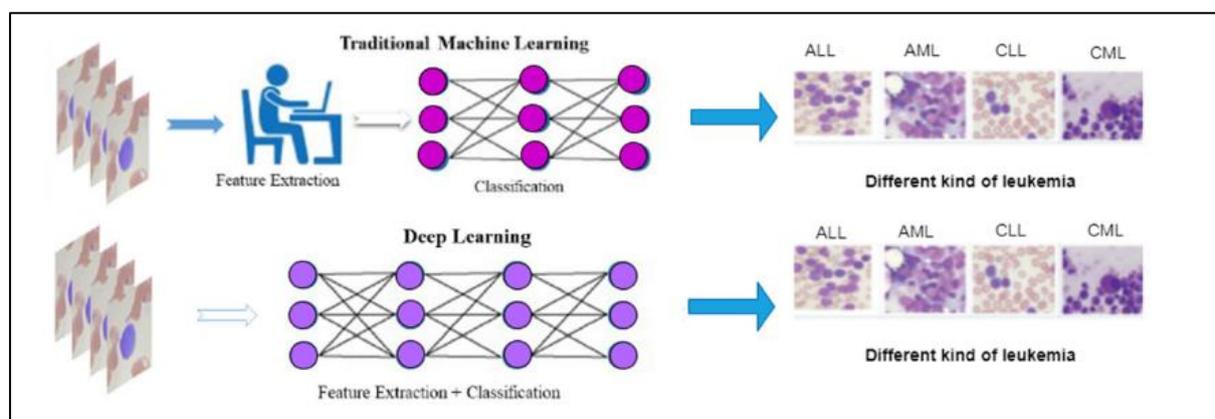


Figure II.2 : Représentation de la différence entre les techniques d'apprentissage automatique et deep Learning pour la classification de la leucémie

II.3 Historique de Deep Learning

Le Deep Learning est un nouveau concept qui a été introduit pour la première fois par Mehta (1986) au Machine Learning, et aux réseaux de neurones par Aizenberg en 2000 [33], sa révolution est liée à la puissance des ordinateurs, également de la quantité de données qui ne cesse de s'accumuler.

On a les différentes phases par lesquelles le Deep Learning s'est développé :

- **1957 Perceptron** : Le perceptron est le réseau de neurone le plus simple, il est composé de neurones qui fonctionnent légèrement différemment que le neurone formel.
- **1986 MLP Les perceptrons multicouches** : les perceptrons multicouches ont pour objectif de classer différentes données selon leur étiquette. Pour cela le perceptron observe chacune des données qu'il possède et met à jour chaque poids de chaque neurone de son réseau afin de classifier au mieux cette base de données
- **1992 SVM Les machines à vecteurs de support** : sont un ensemble de techniques d'apprentissage supervisé destinées à résoudre des problèmes de discrimination et de régression. Les SVM sont une généralisation des classifieurs linéaires [33].
- **2010 Deep Neural Networks** : que l'on appelle un réseau de neurones profond est un perceptron avec au minimum deux couches cachées

II.4 les réseaux de neurones artificiels

Un réseau de neurones est un modèle de calcul dont la conception est très schématiquement inspirée du fonctionnement de vrais neurones (humains ou non). Les RNA (réseaux de neurones artificiels) sont de plus en plus utilisés et appliqués dans différents domaines. Ce concept est lié à la notion d'apprentissage permettant aux ordinateurs d'apprendre par exemple, expérience ou analogie, formant les bases des systèmes adaptatifs.

Un RNA est en général composé d'une succession de couches dont chacune prend ses entrées sur les sorties de la précédente. L'un des avantages d'un RNA est sa capacité à s'adapter aux conditions imposées par un environnement quelconque, et la facilité de rechanger ses paramètres (poids, nombre de neurones, nombre de couches, ...etc.), lors d'une modification possible de cet environnement [34]

II.5 Principe de fonctionnement de réseaux de neuronaux (RN)

En règle générale, un RNA repose sur un grand nombre de processeurs opérant en parallèle et organisés en couches. La première couche reçoit les entrées d'informations brutes, par la suite, chaque couche reçoit les sorties d'informations de la couche précédente. A la fin de la structure, la dernière couche produit les résultats du système (figure II.3) [35].

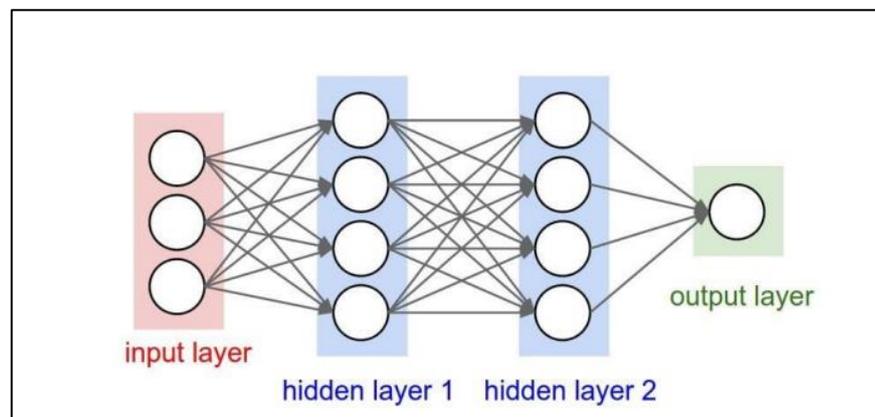


Figure II.3: Schéma d'un réseau de neurones avec deux couches cachées

II.6 Présentation de quelques types de réseaux de neuronaux

II.6.1 Neurone Formel

Le neurone artificiel est une modélisation simplifiée du neurone biologique. Son premier modèle date des années quarante et il a été présenté par Mc Culloch et Pitts. Le neurone formel est une modélisation mathématique qui reprend les principes du fonctionnement du neurone biologique, en particulier la sommation des entrées. La Figure II.4 représente le modèle mathématique d'un neurone artificiel [36]

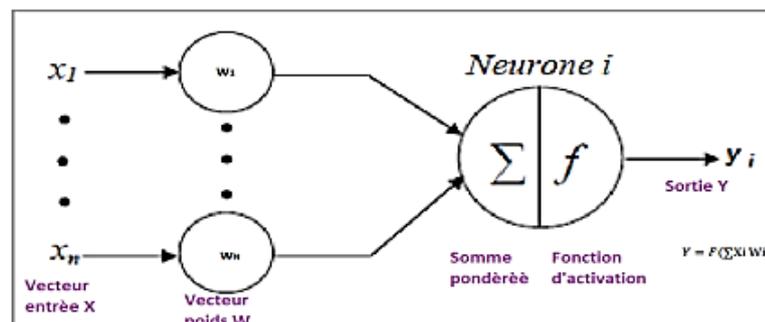


Figure II.4: Modèle d'un neurone formel.

II.6.2 Les Réseaux de Neurones Multicouches

Dans ce type de RNA, les neurones sont arrangés par couche. Il n'y a pas de connexion entre neurones d'une même couche et les neurones transmettent les informations uniquement aux neurones de la couche avale (figure II.5). Généralement, chaque neurone d'une couche est connecté uniquement à tous les neurones de la couche suivante. La couche d'entrée est l'ensemble des neurones d'entrée, et la couche de sortie est l'ensemble des neurones de sortie. Les couches intermédiaires n'ayant aucun contact avec l'extérieur sont appelées les couches cachées [37]

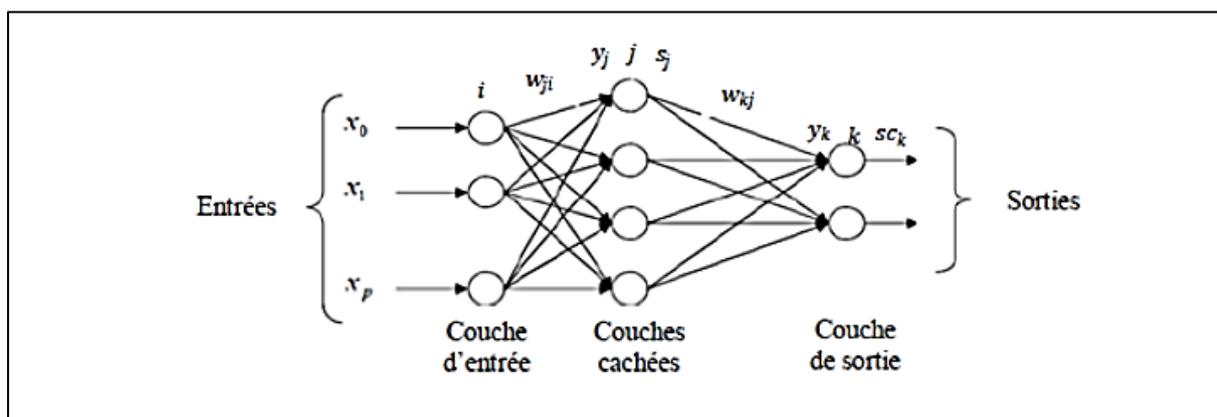


Figure II.5 : structure d'un réseau de neurones multicouche.

II.6.3 Les Réseaux de Neurones Récurrents (ou bouclés)

Un réseau de neurones récurrent ou bouclé (appelé aussi réseau dynamique), est un réseau dont le graphe de connexions peut contenir des cycles. La sortie d'un neurone peut être fonction d'elle-même. la figure II.6 [38] .

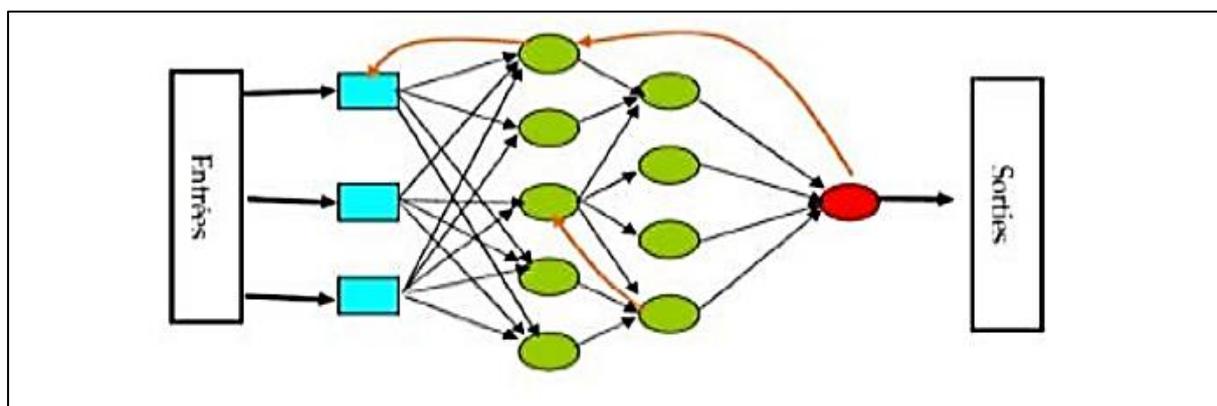


Figure II.6 : Neurones bouclés

II.6.4 Réseau de Neurone Hopfield

Le modèle de Hopfield (fut présenté en 1982) est un modèle basé sur le principe des mémoires associatives. C'est d'ailleurs la raison pour laquelle ce type de réseau est dit associatif. Il utilise l'architecture des réseaux entièrement connectés et récurrents et les sorties sont en fonction des entrées et du dernier état pris par le réseau [39].

II.7 Les réseaux de neurones convolutionnels

Les réseaux de neurones convolutifs désignent une sous-catégorie de réseaux de neurones. Cependant, les CNN sont spécialement conçus pour traiter des images en entrée. Leur architecture est alors plus spécifique : elle est composée de deux blocs principaux.

- 1- **Le premier bloc** fait la particularité de ce type de réseaux de neurones, puisqu'il fonctionne comme un extracteur de features. Pour cela, en appliquant des opérations de filtrage par convolution. La première couche filtre l'image avec plusieurs noyaux de convolution, et renvoie des "feature maps", qui sont ensuite normalisées (avec une fonction d'activation) et/ou redimensionnées. Ce procédé peut être réitéré plusieurs fois : on filtre les features maps obtenues avec de nouveaux noyaux, ce qui nous donne de nouvelles features maps à normaliser et redimensionner, et qu'on peut filtrer à nouveau, et ainsi de suite. Finalement, les valeurs des dernières feature maps sont concaténées dans un vecteur. Ce vecteur définit la sortie du premier bloc, et l'entrée du second.
- 2- **Le second bloc** : Les valeurs du vecteur en entrée sont transformées (avec plusieurs combinaisons linéaires et fonctions d'activation) pour renvoyer un nouveau vecteur en sortie. Ce dernier vecteur contient autant d'éléments qu'il y a de classes : l'élément i représente la probabilité que l'image appartienne à la classe i . Comme pour les réseaux de neurones ordinaires, les paramètres des couches sont déterminés par rétropropagation du gradient : l'entropie croisée est minimisée lors de la phase d'entraînement. Mais dans le cas des CNN, ces paramètres désignent en particulier les features des images. Voir maintenant les différents types de couches d'un CNN. Il existe quatre types de couches pour un réseau de neurones convolutif : la couche de convolution, la couche de pooling, la couche de correction ReLU et la couche fully-connected [40].

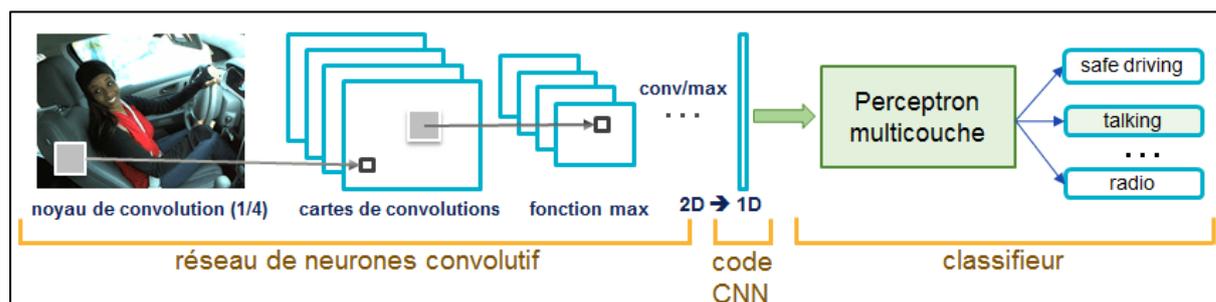


Figure II.7 : Schéma représentant l'architecture d'un CNN

II.8 Architecture d'un Les réseaux de neurones convolutionnels (CNN)

Il existe quatre types de couches pour un réseau de neurones convolutif : la couche de **convolution**, la couche de **pooling**, la couche de **correction ReLU** et la couche **fully-connected**.

Dans la suite, nous allons expliquer le fonctionnement de ces différentes couches [41].

II.8.1 Couche de convolution(CONV)

Le terme "convolution" vient du fait que les réseaux CNN utilisent des opérations de convolution comme dans le traitement du signal ou d'images[42]. Dans la couche de convolution, on applique un produit de convolution entre l'image originale ou celle obtenue dans la couche précédente avec un filtre dont des coefficients sont assimilés à des poids synaptiques [43].

Le produit de convolution d'une matrice (image dans ce cas) I avec un filtre K de taille $(s*s)$ est:

$$O(x, y) = \sum_{i=0}^2 \sum_{j=0}^2 K(i, j) \times I(x - 1 + j, y - 1 + i) \quad (\text{II.1})$$

Il y a trois paramètres permettent de dimensionner le volume de la couche de convolution la profondeur, le pas et la marge :

i. Profondeur de la couche: Nombre de noyaux de convolution (ou nombre de neurones associés à un même champ récepteur) [43].

ii. Le pas: Contrôle le chevauchement des champs récepteurs. Plus le pas est petit, plus les champs récepteurs se chevauchent et plus le volume de sortie sera grand [43].

iii. La marge (à 0) ou zéro padding: Parfois, il est commode de mettre des zéros à la frontière du volume d'entrée. La taille de ce 'zéro-padding' est le troisième hyper paramètre. Cette marge permet de contrôler la dimension spatiale du volume de sortie. En particulier, il est parfois souhaitable de conserver la même surface que celle du volume d'entrée. Si le pas et la marge appliquée à l'image d'entrée permettent de contrôler le nombre de champs récepteurs à gérer (surface de traitement), la profondeur permet d'avoir une notion de volume de sortie, et de la même manière qu'une image peut avoir un volume, si on prend une profondeur de 3 pour les trois canaux RGB d'une image couleur, la couche de convolution va également présenter en sortie une profondeur. C'est pour cela que l'on parle plutôt de « volume de sortie » et de « volume d'entrée », car l'entrée d'une couche de convolution peut être soit une image soit la sortie d'une autre couche de convolution. [43]

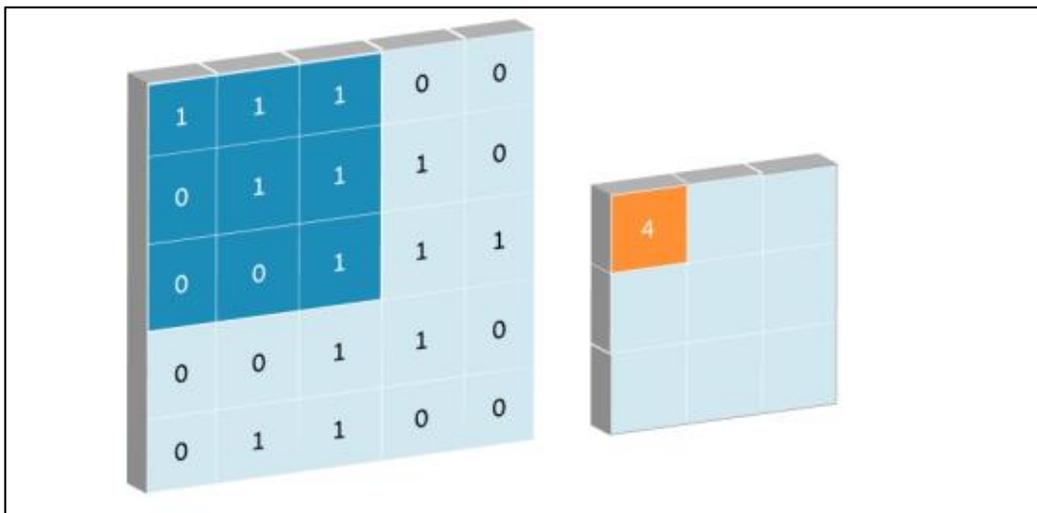


Figure II.8 : Exemple de filtre de taille (3*3)

La couche de convolution est la composante clé des réseaux de neurones convolutifs, et constitue toujours au moins leur première couche. Son but est de repérer la présence d'un ensemble de features dans les images reçues en entrée. Pour cela, on réalise un filtrage par convolution : le principe est de faire "glisser" une fenêtre représentant la feature sur l'image, et de calculer le produit de convolution entre la feature et chaque portion de l'image balayée. Une feature est alors vue comme un filtre : les deux termes sont équivalents dans ce contexte

La couche de convolution reçoit donc en entrée plusieurs images, et calcule la convolution de chacune d'entre elles avec chaque filtre. Les filtres correspondent exactement aux features que l'on souhaite retrouver dans les images.

On obtient pour chaque paire (image, filtre) une carte d'activation, ou feature map, qui nous indique où se situent les features dans l'image : plus la valeur est élevée, plus l'endroit correspondant dans l'image ressemble à la feature.

Contrairement aux méthodes traditionnelles, les features ne sont pas prédéfinies selon un formalisme particulier, mais apprises par le réseau lors la phase d'entraînement ! Les noyaux des filtres désignent les poids de la couche de convolution. Ils sont initialisés puis mis à jour par rétropropagation du gradient.

C'est là toute la force des réseaux de neurones convolutifs : ceux-ci sont capables de déterminer tout seul les éléments discriminants d'une image, en s'adaptant au problème posé.

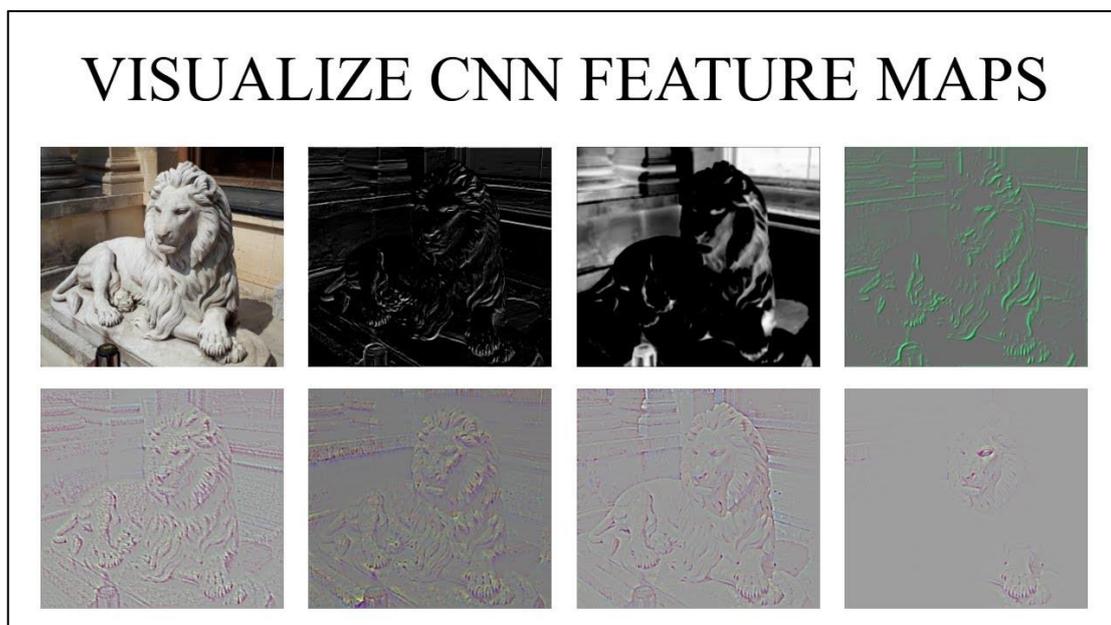


Figure II.9 : Exemple des features maps résultants de la convolution

II.8.2 Couche de Pooling

L'étape de pooling est une technique de sous-échantillonnage. Généralement, une couche de pooling est insérée régulièrement entre les couches de correction et de convolution. En réduisant la taille des cartes de caractéristiques, donc le nombre de paramètres du réseau, cela accélère le temps de calcul et diminue le risque de sur-apprentissage.

Il y a de nombreuses opérations dans cette couche, par exemple Max pooling et Average pooling [44].

• **Mise en commun maximale (Max-pooling)** : Il s'agit d'une opération de pooling qui ne prélèvera que le maximum d'un pool. Cela se fait en fait avec l'utilisation de filtres glissant à travers l'entrée ; et à chaque foulée, le paramètre maximum est retiré et le reste est abandonné. Cela sous-échantillonne en fait le réseau [44].

• **Mise en commun moyenne (Average pooling)** : Est une opération de regroupement qui calcule la valeur moyenne d'un pool et l'utilise pour créer un sous-échantillonnage (regroupé), elle extrait les fonctionnalités plus facilement que Max Pooling. La figure 2.8 montre un exemple d'opération de max pooling et Average pooling avec une taille de filtre 2x2 pixels à partir d'une entrée de pixels 4x4 [44]

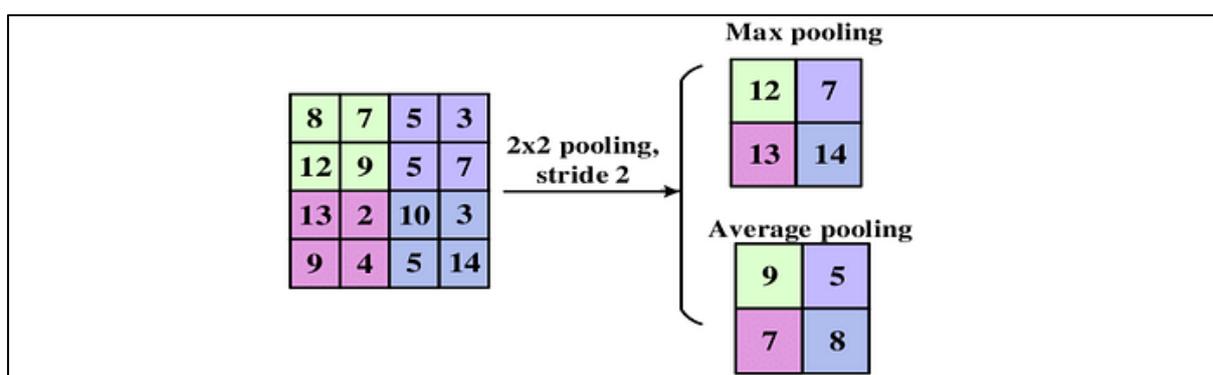


Figure II.10: max et arevage pooling

II.8.3 la couche ReLU

Pour améliorer l'efficacité du traitement en intercalant entre les couches de traitement une couche qui va opérer une fonction mathématique (fonction d'activation) sur les signaux de sortie. Dans ce cadre on trouve

ReLU (Rectified Linear Units) désigne la fonction réelle non-linéaire définie par $\text{ReLU}(x) = \max(0, x)$.

La couche de correction ReLU remplace donc toutes les valeurs négatives reçues en entrées par des zéros. Elle joue le rôle de fonction d'activation

Souvent, la correction Relu est préférable, mais il existe d'autre forme

- La correction par tangente hyperbolique $f(x) = \tanh(x)$,
- La correction par la tangente hyperbolique saturante: $f(x) = |\tanh(x)|$,
- La correction par la fonction sigmoïde :

$$\left\{ \displaystyle f(x) = \frac{1}{1 + e^{-x}} \right\}. F(x) = (1 + e^{-x})^{-1} \quad [40]$$

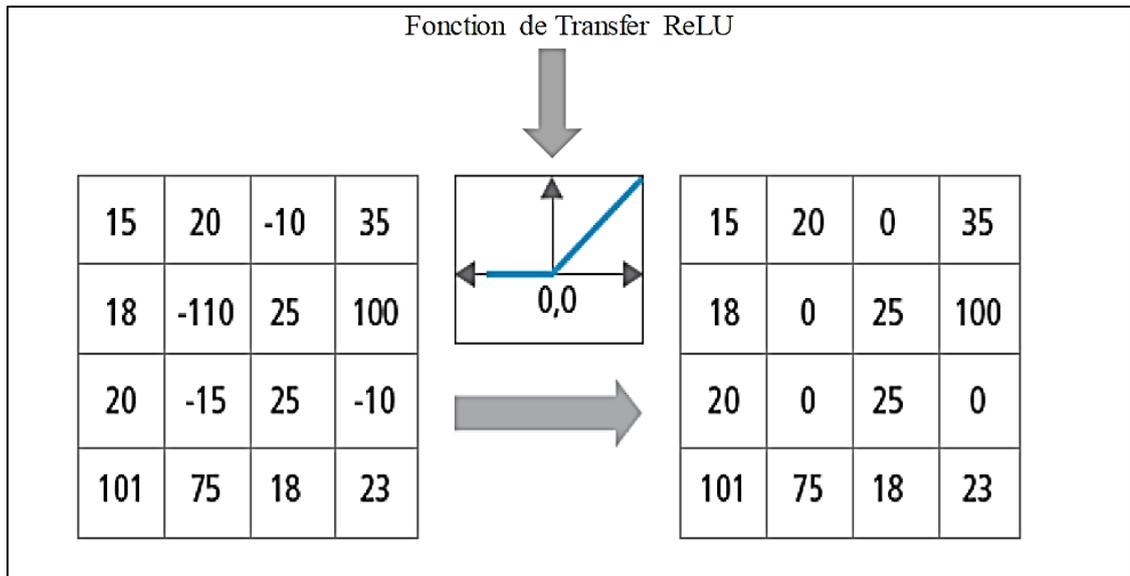


Figure II.11: Représentation graphique de la fonctionnalité Relu.

II.8.4 Couche fully-connected

La dernière couche fully-connected permet de classifier l'image en entrée du réseau : elle renvoie un vecteur de taille N, où N est le nombre de classes dans le problème de classification d'images. Chaque élément du vecteur indique la probabilité pour l'image en entrée d'appartenir à une classe [45].

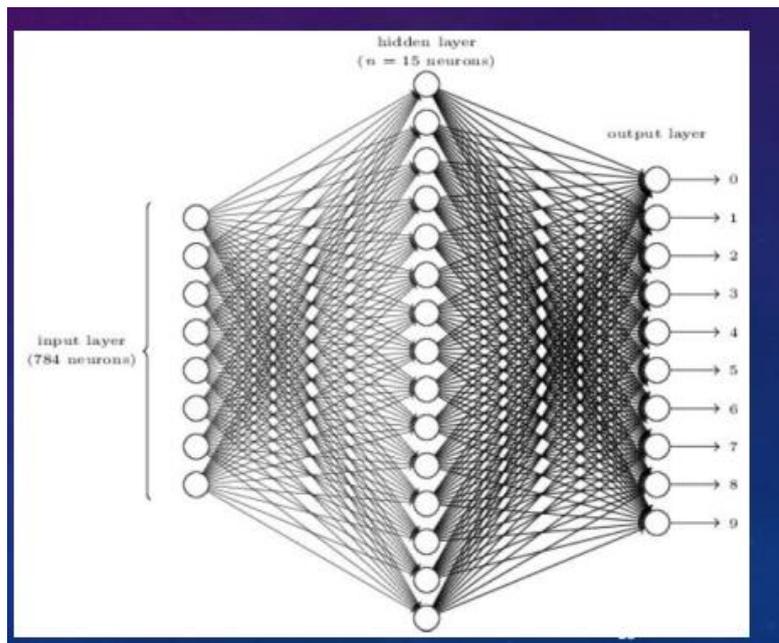


Figure II.12: fully-connected layers

II.8.5 Couche de perte (LOSS)

La couche de perte est la dernière couche du réseau. Elle calcule l'erreur entre la prévision du réseau et la valeur réelle. Lors d'une tâche de classification, la variable aléatoire est discrète, car elle peut prendre uniquement les valeurs 0 ou 1, représentant l'appartenance (1) ou non (0) à une classe. C'est pourquoi la fonction de perte la plus courante et la plus adaptée est la fonction d'entropie croisée (en anglais cross-entropy).

Celle-ci est issue du domaine de la théorie de l'information, et mesure la différence globale entre deux distributions de probabilité (celle de la prévision du modèle, celle du réel) pour une variable aléatoire ou un ensemble d'évènements [46]. Formellement, elle s'écrit :

$$\text{loss}(x, \text{class}) = - \sum_{\text{class}=1}^C y_{x, \text{class}} \log P_{x, \text{class}} \quad (\text{II.2})$$

Avec y la probabilité estimée d'appartenance de x à la classe i , p la probabilité réelle d'appartenance de x à la classe i , sachant qu'il y a C classes.

II.9. Choix des paramètres :

Les CNNs utilisent plus de paramètres qu'un MLP standard. Même si les règles habituelles pour les taux d'apprentissage et des constantes de régularisation s'appliquent toujours, il faut prendre en considération les notions de nombre de filtres, leur forme et la forme du max pooling.

II.9.1 Nombre de filtres :

Comme la taille des images intermédiaires diminue avec la profondeur du traitement, les couches proches de l'entrée ont tendance à avoir moins de filtres tandis que les couches plus proches de la sortie peuvent en avoir davantage. Pour égaliser le calcul à chaque couche, le produit du nombre de caractéristiques et le nombre de pixels traités est généralement choisi pour être à peu près constant à travers les couches [47].

II.9.2 Forme du filtre :

Ils sont généralement choisis en fonction de l'ensemble de données. Les meilleurs résultats sur les images de MNIST (28x28) sont habituellement dans la gamme de 5x5 sur la première couche, tandis que les ensembles de données d'images naturelles (souvent avec des centaines de pixels dans chaque dimension) ont tendance à utiliser de plus grands filtres de première couche de 12x12, voire 15x15. Le défi est donc de trouver le bon niveau de granularité de manière à créer des abstractions à l'échelle appropriée et adaptée à chaque cas [47].

II.9.3 Forme du Max Pooling :

Les valeurs typiques sont 2x2. De très grands volumes d'entrée peuvent justifier un pooling 4x4 dans les premières couches. Cependant, le choix de formes plus grandes va considérablement réduire la dimension du signal, et peut entraîner la perte de trop d'information[47].

II.10 Les réseaux CNN :

➤ LeNet :

LeNet est la première architecture CNN. Elle a été développée en 1998 par Yann LeCun, Corinna Cortes et Christopher Burges [48] pour des problèmes de reconnaissance de chiffre manuscrits. LeNet a été l'un des premiers CNN réussis et est souvent considéré comme le "Hello World" de l'apprentissage profond. Il s'agit de l'une des architectures CNN les plus anciennes et les plus largement utilisées, qui a été appliquée avec succès à des tâches telles que la reconnaissance de chiffres manuscrits.

L'architecture LeNet se compose de plusieurs couches de convolution et de mise en commun, suivies d'une couche entièrement connectée. Le modèle comporte cinq couches de convolution suivies de deux couches entièrement connectées. LeNet a marqué le début des CNN dans le domaine de l'apprentissage profond pour les problèmes de vision par ordinateur. Cependant, LeNet ne pouvait pas s'entraîner correctement en raison du problème des gradients qui s'évanouissent. Pour résoudre ce problème, une couche de connexion raccourcie connue sous le nom de "max-pooling" est utilisée entre les couches convolutives pour réduire la taille spatiale des images, ce qui permet d'éviter l'ajustement excessif et permet aux CNN de s'entraîner plus efficacement.

La figure II.13 représente l'architecture de LeNet-5.

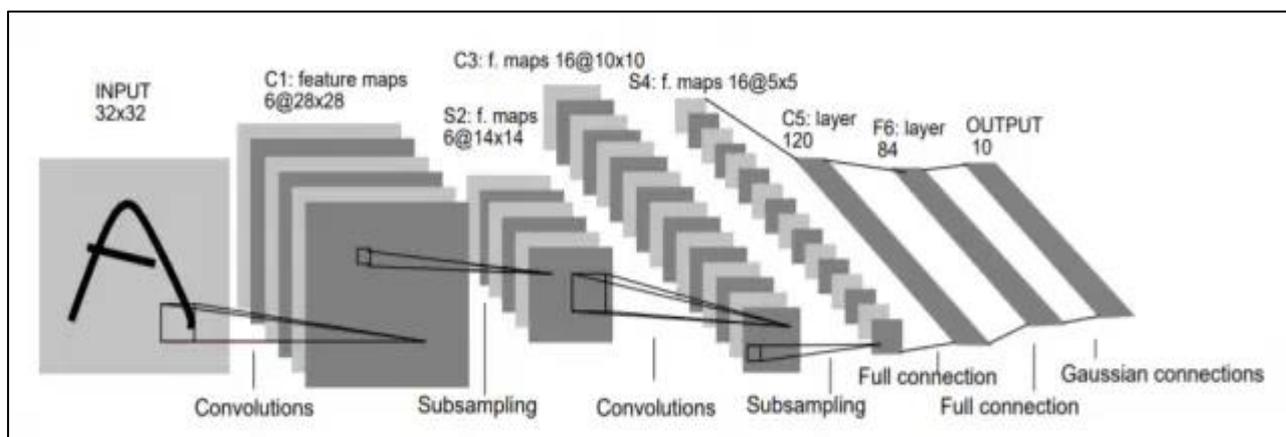


Figure II.13: Architecture of convolutional neural network Net

Bien que LeNet ait été développé il y a plus de 20 ans, son architecture est toujours d'actualité et continue d'être utilisée.

➤ **AlexNet :**

AlexNet est l'architecture d'apprentissage profond qui a popularisé le CNN. Elle a été développée par Alex Krizhevsky, Ilya Sutskever et Geoff Hinton.[49] Le réseau AlexNet a une architecture très similaire à celle de LeNet, mais il est plus profond, plus grand et comporte des couches convolutives empilées les unes sur les autres. AlexNet a été le premier CNN à grande échelle et a été utilisé pour remporter l'ImageNet Large Scale Visual Recognition Challenge (ILSVRC) en 2012. L'architecture d'AlexNet a été conçue pour être utilisée avec des ensembles de données d'images à grande échelle et a obtenu des résultats de pointe au moment de sa publication. AlexNet est composé de 5 couches convolutives avec une combinaison de couches de mise en commun maximale, de 3 couches entièrement connectées et de 2 couches d'exclusion. La fonction d'activation utilisée dans toutes les couches est Relu. La fonction d'activation utilisée dans la couche de sortie est Softmax. Le nombre total de paramètres dans cette architecture est d'environ 60 millions.

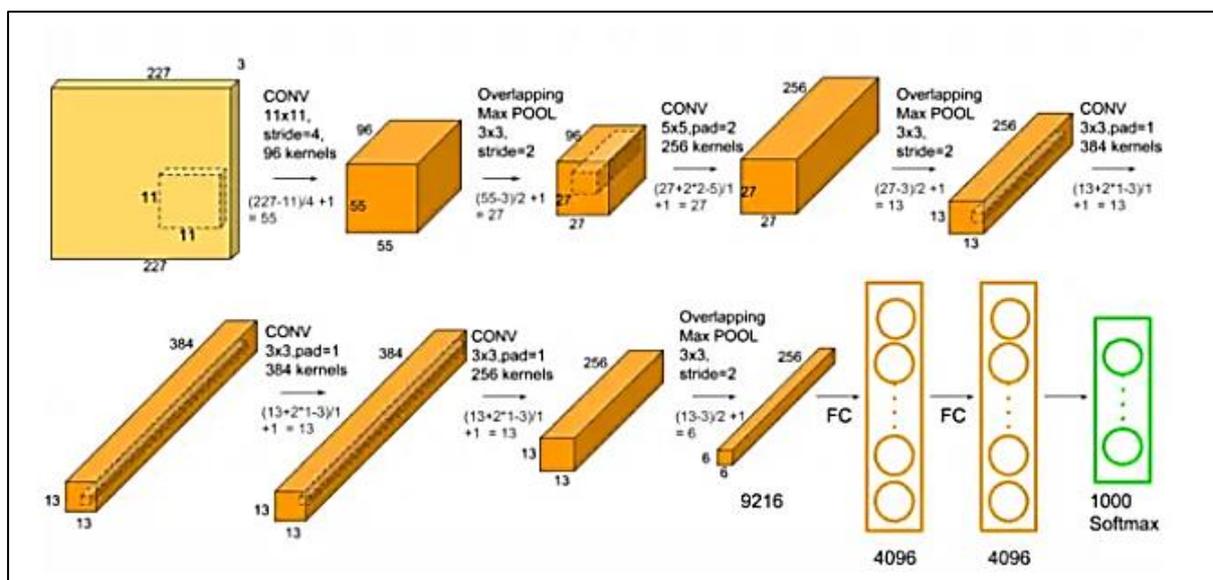


Figure II.14: Architecture of convolutional neural network AlexNet

➤ **GoogLeNet :**

GoogLeNet est l'architecture CNN utilisée par Google pour remporter la tâche de classification ILSVRC 2014. Elle a été développée par Jeff Dean, Christian Szegedy, Alexandro Szegedy et al [50]Il a été démontré qu'elle avait un taux d'erreur considérablement réduit par

rapport aux gagnants précédents AlexNet (gagnant de l'Ilsvrc 2012) et ZF-Net (gagnant de l'Ilsvrc 2013). En termes de taux d'erreur, l'erreur est significativement inférieure à VGG (2014 runner up). L'architecture est plus profonde grâce à l'utilisation d'un certain nombre de techniques distinctes, notamment la convolution 1×1 et la mise en commun de la moyenne globale. L'architecture CNN de GoogleNet est coûteuse en termes de calcul.

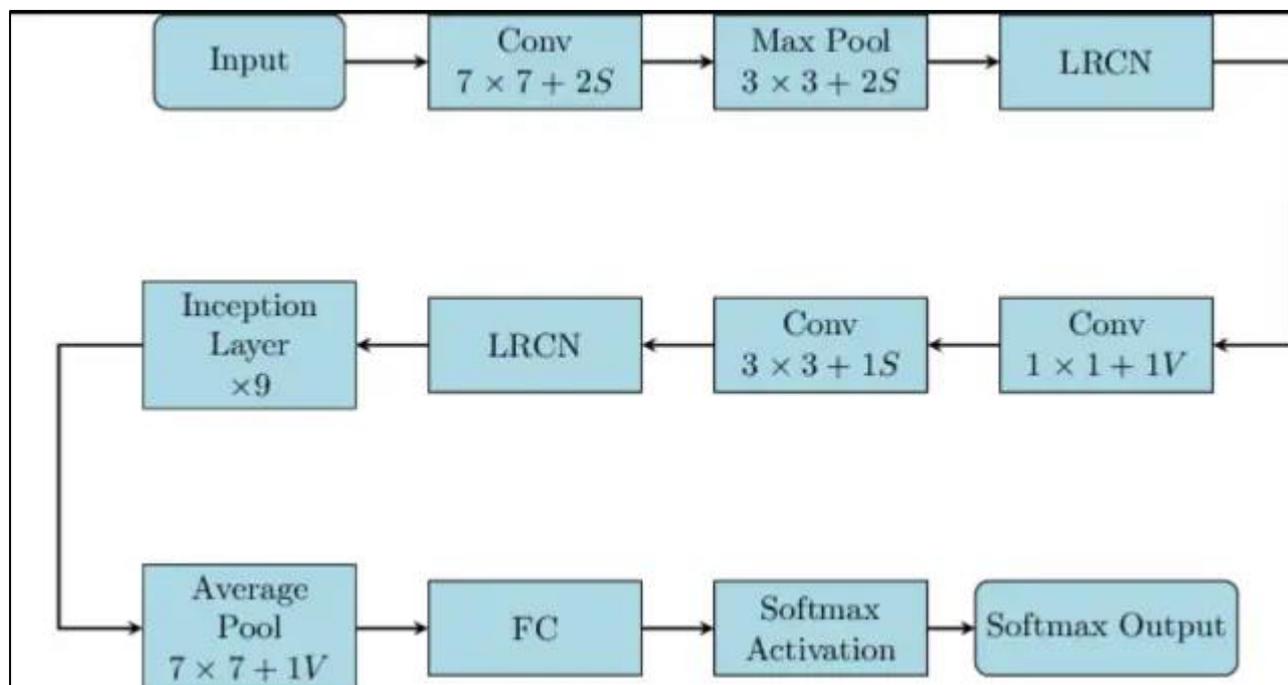


Figure II.15: Architecture de Google Net.

➤ **VGGNet :**

VGGNet est l'architecture CNN développée par Karen Simonyan, Andrew Zisserman et al.[51] à l'Université d'Oxford. VGGNet est un CNN à 16 couches avec jusqu'à 95 millions de paramètres et entraîné sur plus d'un milliard d'images (1000 classes). Il peut prendre de grandes images d'entrée de 224×224 pixels pour lesquelles il dispose de 4096 caractéristiques convolutives. Les CNN dotés de filtres aussi grands sont coûteux à former et nécessitent beaucoup de données. C'est la principale raison pour laquelle les architectures CNN telles que GoogLeNet (architecture AlexNet) fonctionnent mieux que VGGNet pour la plupart des tâches de classification d'images où les images d'entrée ont une taille comprise entre 100×100 pixels et 350×350 pixels. Parmi les applications/exemples réels de l'architecture CNN VGGNet, on peut citer la tâche de classification ILSVRC 2014, qui a également été remportée par l'architecture CNN GoogleNet. Le modèle VGG CNN est efficace sur le plan des calculs et sert de base solide pour de nombreuses applications en vision par ordinateur en raison de son applicabilité à de nombreuses

tâches, y compris la détection d'objets. Ses représentations profondes des caractéristiques sont utilisées dans de nombreuses architectures de réseaux neuronaux telles que YOLO, SSD, etc. Le diagramme ci-dessous représente l'architecture standard du réseau VGG16 :

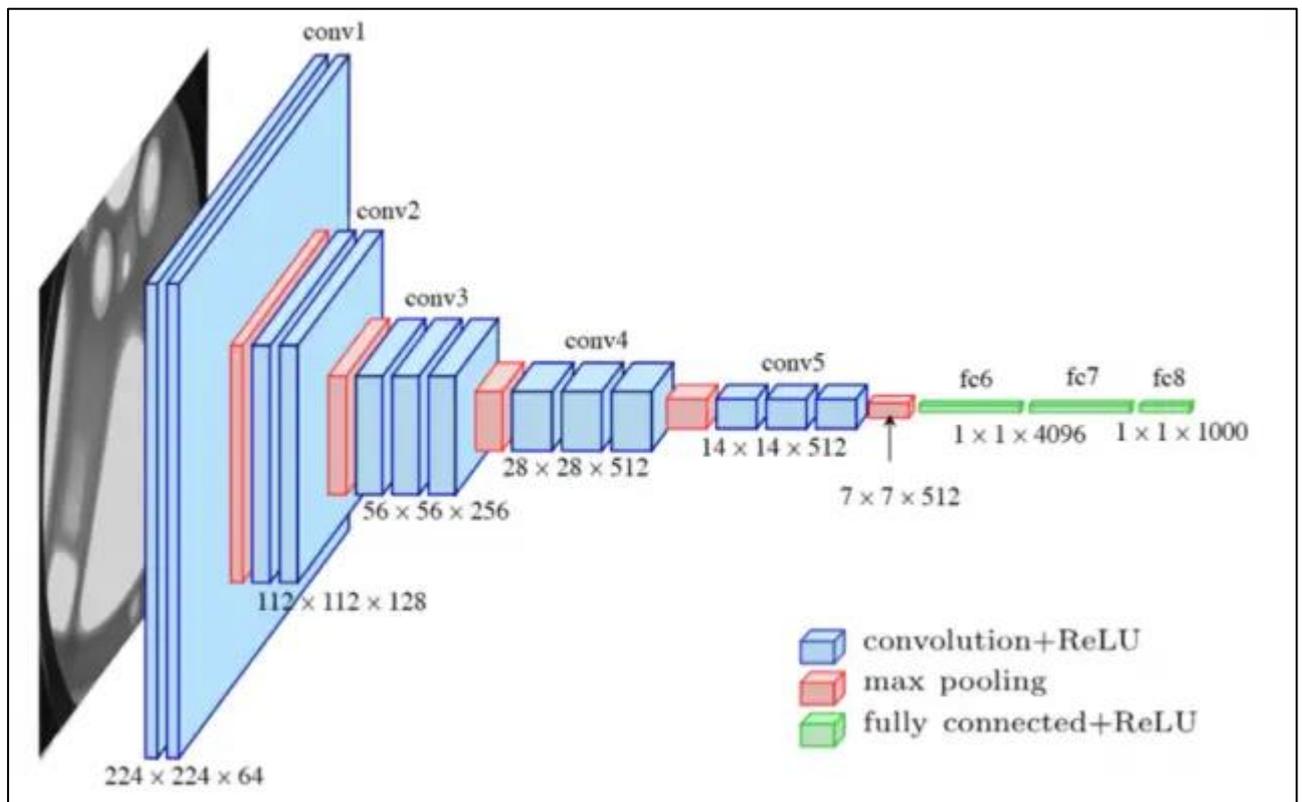


Figure II.16: Architecture of convolutional neural network VGG

➤ **ResNet :**

ResNet est l'architecture CNN développée par Kaiming He et al. [52] pour remporter la tâche de classification ILSVRC 2015 avec une erreur de seulement 15,43 % dans le top 5. Le réseau comporte 152 couches et plus d'un million de paramètres, ce qui est considéré comme profond même pour des CNN, car il aurait fallu plus de 40 jours sur 32 GPU pour entraîner le réseau sur l'ensemble de données de l'ILSVRC 2015. Les CNN sont principalement utilisés pour des tâches de classification d'images avec 1000 classes, mais ResNet prouve que les CNN peuvent également être utilisés avec succès pour résoudre des problèmes de traitement du langage naturel tels que l'achèvement de phrases ou la compréhension automatique, où il a été utilisé par l'équipe Microsoft Research Asia en 2016 et 2017 respectivement. Parmi les applications/exemples réels de l'architecture CNN ResNet, on peut citer le système de compréhension automatique de Microsoft, qui a utilisé les CNN pour générer les réponses à plus de 100 000 questions dans plus

de 20 catégories. L'architecture CNN ResNet est efficace sur le plan du calcul et peut être augmentée ou réduite pour s'adapter à la puissance de calcul des GPU.

➤ **MobileNets :**

MobileNets sont des CNN qui peuvent être installés sur un appareil mobile pour classer des images ou détecter des objets avec une faible latence. Les MobileNets ont été développés par Andrew G Trillion et al. Il s'agit généralement d'architectures CNN de très petite taille, ce qui les rend faciles à exécuter en temps réel à l'aide d'appareils embarqués tels que les smartphones et les drones. L'architecture est également flexible, elle a donc été testée sur des CNN de 100 à 300 couches et fonctionne toujours mieux que d'autres architectures comme VGGNet. Parmi les exemples concrets de l'architecture CNN de MobileNets, on peut citer les CNN intégrés dans les téléphones Android pour exécuter l'API Mobile Vision de Google, qui permet d'identifier automatiquement les étiquettes d'objets populaires dans les images [52].

II.11 Transfer Learning : Adapter des CNN pré-entraînés

Toute la complexité de création de CNN peut être évitée en adaptant des réseaux pré-entraînés disponibles publiquement. Ces techniques sont appelées **transfer learning**, car on exploite la connaissance acquise sur un problème de classification général pour l'appliquer de nouveau à un problème particulier.

La "connaissance" sur la classification d'images contenue dans un tel réseau peut être exploitée de deux façons :

- ✓ comme un **extracteur automatique de caractéristiques** des images, matérialisé par le code CNN. Une méthode simple et performante !
- ✓ en **Fine Tuning**, comme une initialisation du modèle, qui est ensuite ré-entraîné plus finement pour traiter le nouveau problème de classification. Une méthode qui demande plus d'investissement (technique, GPU) mais permet de faire monter la performance.

➤ **Extraction automatique de caractéristiques**

L'extraction automatique de caractéristiques exploite uniquement la partie convolutive d'un réseau pré-entraîné. Elle l'utilise comme extracteur de caractéristiques des images (code CNN), pour alimenter un classifieur. .

Malgré sa simplicité, cette méthode offre déjà de très bonnes performances. Le réseau permet d'extraire des caractéristiques (features) généralement très pertinentes, à haut niveau d'abstraction. Cela réduit la dimension du problème, en remplacement de méthodes de traitement d'images classiques, mais sophistiquées.

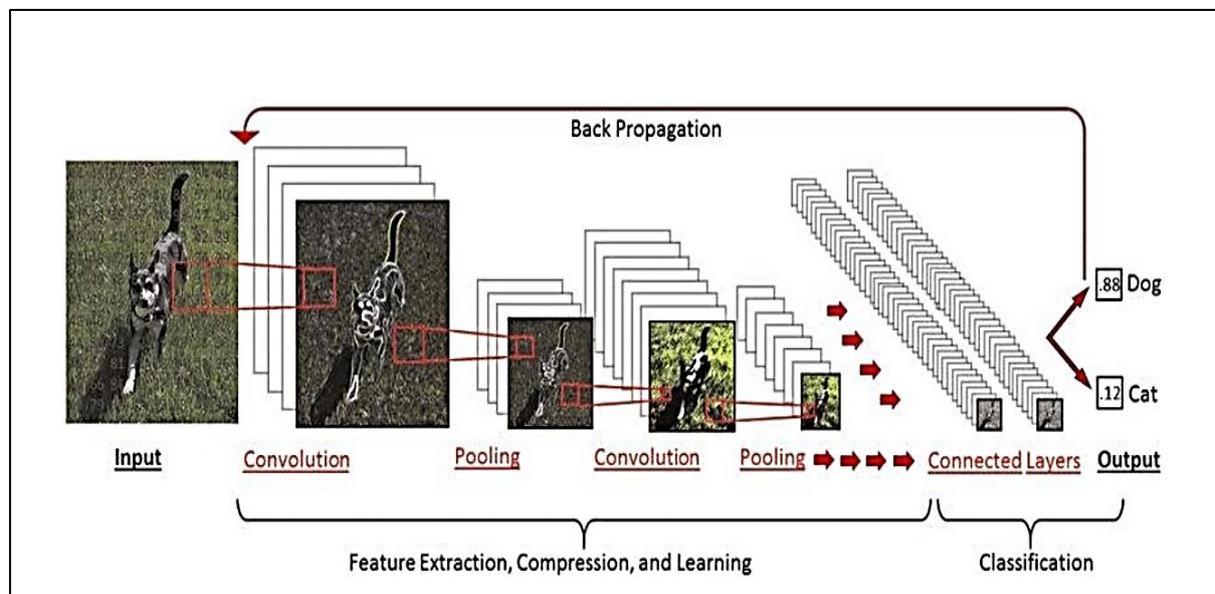


Figure II.17 : exemple de modèle de CNN utilisé pour la classification d'images

➤ Fine Tuning

Le Fine Tuning consiste à se servir d'un modèle pré-entraîné comme initialisation pour l'entraînement sur un nouveau problème. L'intérêt est double : on utilise une architecture optimisée avec soin par des spécialistes, et l'on profite des capacités d'extraction de caractéristiques apprises sur un jeu de données de qualité. Le Fine Tuning sur des images consiste en quelques sortes à prendre un système visuel déjà bien entraîné sur une tâche de classification pour le raffiner sur une tâche similaire.

La seule modification *nécessaire* du réseau consiste à adapter la dernière couche, pour correspondre au nombre de catégories de notre problème. Cela peut fortement modifier les ratios de tailles entre couches successives, qui correspondent à des réductions de dimension de l'information. Il est envisageable d'ajouter une couche intermédiaire avant la sortie, ou de modifier la taille des couches préalables.

Pour l'entraînement, il est possible de geler les couches initiales du réseau de neurones, et de n'adapter que les couches finales pour le nouveau problème de classification. Geler toutes les

couches convolutives correspond à la première méthode présentée, avec comme classifieur final un perceptron multicouche pré-initialisé.

Les principes généraux d'entraînement des CNN s'appliquent au Fine Tuning. Un point d'attention spécifique est l'utilisation de faibles taux d'apprentissage.

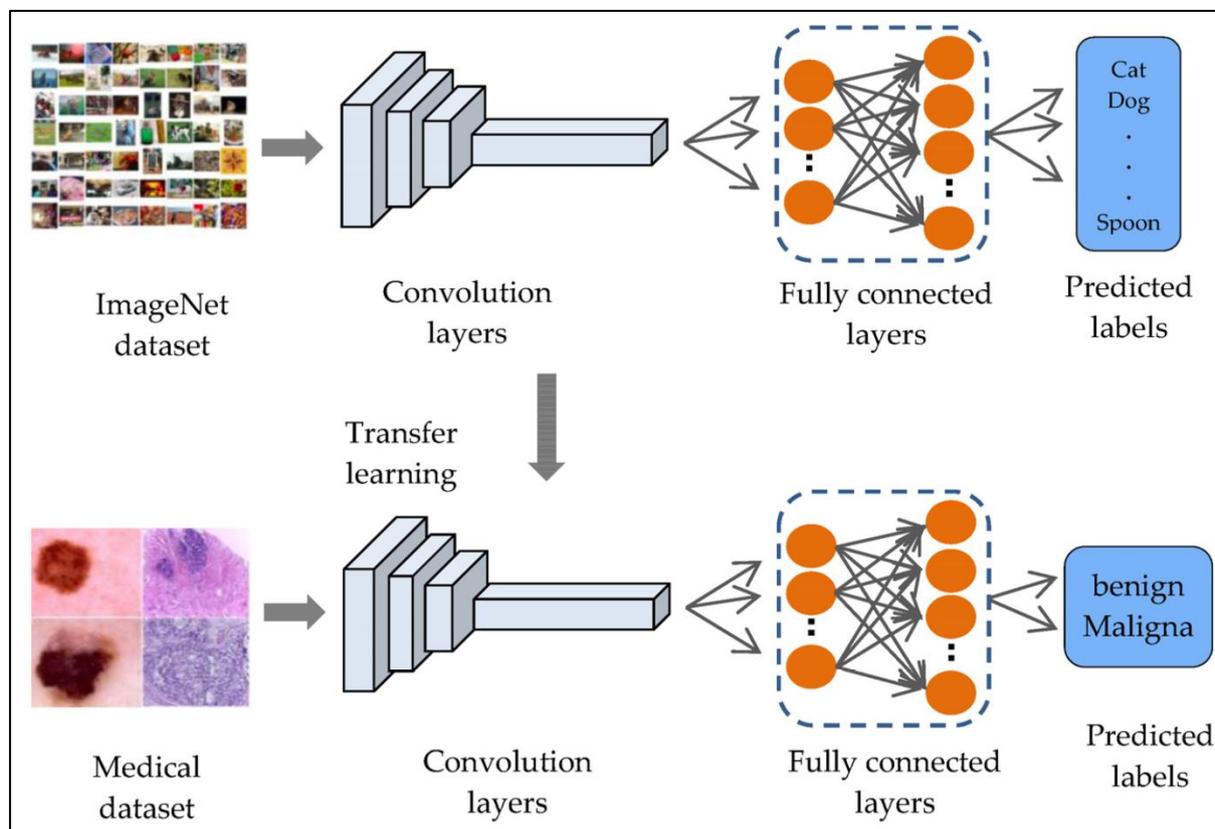


Figure II.18 : le transfer learning en utilisant le Fine tuning

II.12. Conclusion

Dans ce chapitre, nous avons présenté les réseaux de neurones convolutionnels. Ces réseaux sont capables d'extraire des caractéristiques d'images présentées en entrée et de classifier ces caractéristiques, Ils sont fondés sur la notion de « champs récepteurs » (receptive fields), ils implémentent aussi l'idée de partage des poids qui permettant de réduire beaucoup de nombre de paramètres libres de l'architecture. Ce partage des poids permet en outre de réduire les temps de calcul, l'espace mémoire nécessaire, et également d'améliorer les capacités de généralisation du réseau.

Les réseaux de neurones convolutionnels présentent cependant un certain nombre de limitations, en premier lieu, les hyper paramètres du réseau sont difficiles à évaluer a priori. En

effet, le nombre de couches, le nombre de neurones par couche ou encore les différentes connexions entre couches sont des éléments cruciaux et essentiellement déterminés par une bonne intuition ou par une succession de tests/calcul d'erreurs (ce qui est coûteux en temps). Le nombre d'échantillons d'apprentissage est également un élément déterminant, et il arrive souvent que celui-ci soit trop faible en comparaison du nombre de paramètres (poids) du réseau. Dans le chapitre suivant, on va exploiter les CNN comme extracteur de caractéristiques pour classer la leucémie en deux classes.

Chapitre III

Tests et Résultats

III.1. Introduction

Il est important de diagnostiquer et de traiter rapidement les leucémies aiguës lymphoblastiques ALL, car elles peuvent être rapidement évolutives et potentiellement mortelles si elles ne sont pas prises en charge. Un suivi régulier après le traitement est également nécessaire pour évaluer la réponse au traitement et détecter toute rechute éventuelle.

L'amélioration de la rapidité d'obtention des résultats de diagnostic dans les cas de maladies résistantes telles que le cancer est un aspect important pour améliorer les chances de traitement et les résultats globaux des patients. Parmi les outils d'apprentissage en profondeur utilisés pour atteindre cet objectif se trouvent les réseaux neuronaux profonds CNN.

Les réseaux neuronaux profonds sont basés sur le concept de l'apprentissage automatique, où ils sont entraînés sur un grand ensemble de données et apprennent des représentations avancées et complexes de ces données. Grâce à cet apprentissage en profondeur, le réseau neuronal profond est capable d'extraire efficacement et rapidement les caractéristiques et les motifs importants des images et des données massives.

Dans ce chapitre, nous présentons une approche basée sur l'application des CNN la classification de la leucémie aigüe connue sous le nom *acute lymphocytic leucémie* (ALL), en utilisant une base de données d'images médicales.

III.2. La base de données

La base de données utilisée dans ce travail C-NMC 2019 a été fourni par l'équipe de recherche de SBILab [53]. La base de données [54] se compose de 15 114 images de lymphocytes collectées auprès de 118 sujets. Ces images ont été divisées en ensembles d'entraînement, de validation et de test (Tableau III.1). Chaque ensemble d'images contient des images de cellules individuelles de lymphocytes sains ou malins précédemment étiquetées par une équipe d'oncologues en deux classes cellules malade (*acute lymphocytic leukemia ALL*) et cellules saines (HEM)

Les cellules ont été colorées à l'aide de la technique de coloration de Jenner-Giemsa [56]. L'équipe de *SBILab* a prétraité ces images en utilisant des techniques de segmentation, d'amélioration d'image et de normalisation [57, 58, 59]. Les lymphocytes individuels ont été segmentés à partir d'images de frottis sanguins et placés au centre de ces images, chaque image

mesure 450×450 pixels et a un fond noir. La Figure 1 montre des échantillons de cellules saines et malignes de cette base de données.



Figure III.1 : Exemple des images ALL

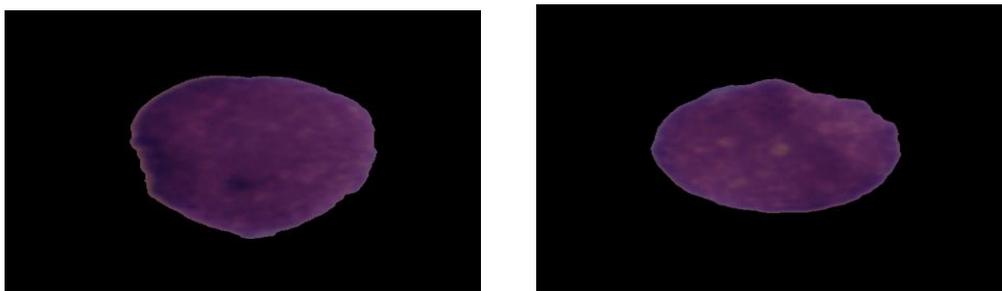


Figure III. 2 : Exemple des images HEM

	Original	
	Malignant	Healthy
Training	5923 (42)	3035 (29)
Validation	1531 (12)	506 (8)
Test	1007 (6)	496 (4)

Tableau III.1 : Nombre d'échantillons dans les ensembles d'entraînement, de validation et de test. Le nombre de patients est indiqué entre parenthèses.[55]

A cause de la limitation du matériel informatique, nous avons choisi un nombre réduit de la base de données pour tester notre approche dont le but est de classer les images des cellules en deux classes ALL et HEM

	ALL	hem
Nombre des images	2397	1130

Tableau III.2 : Nombre des images utilisées

III.3 Étude expérimentale

Pour réaliser notre travail, nous avons utilisé un ordinateur portable **acer** avec les caractéristiques suivantes :

- ✓ Processeur : Intel(R) Core (TM) i3-5005U CPU.
- ✓ Vitesse d'horloge : 2.00 GHz.
- ✓ Capacité Mémoire (RAM) :8.00 Go.
- ✓ Système d'exploitation : 64 bits , processeur ×64
- ✓ Windows 8.1 professionnel pour la réalisation de notre système nous avons choisi le langage de programmation MATLAB (R2021a).

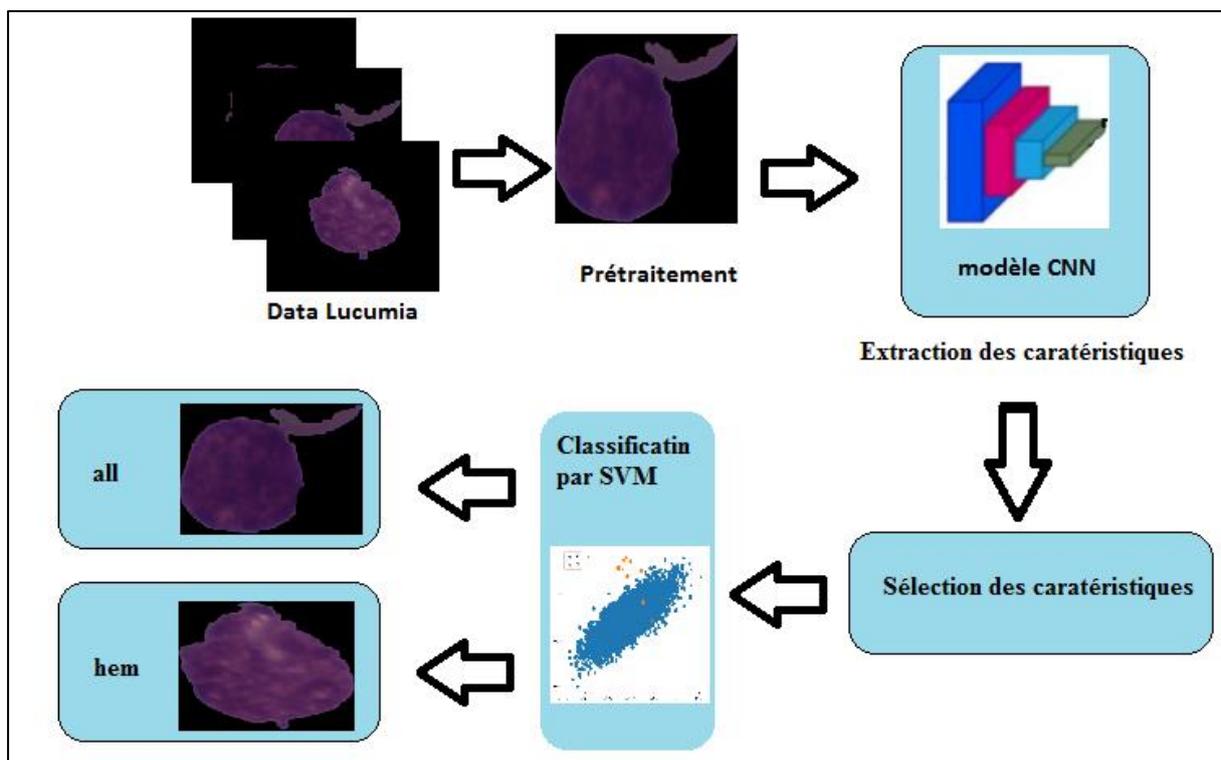


Figure III.3 : Approche implémentée pour la classification de la leucémie

III.3.1 Prétraitements

Chaque image de la base de données de la leucémie contient des zones indésirables et des espaces vides. Par conséquent, le recadrage des images est essentiel pour éliminer l'espace inutile et n'utiliser que les informations vitales. Nous avons appliqué la méthodologie de calcul des points extrêmes pour recadrer les images utilisée dans cette étude. La figure III. 4 est un exemple de ce

traitement qui contient le chargement de l'image de la leucémie, sa transformation en niveaux de gris, puis l'application d'un seuil à l'image pour la convertir en une image binaire. Ensuite, le calcul des quatre points minimum et maximum du contour déterminé. Enfin, recadrage (cropping) de l'image en utilisant les données recueillies à partir des points de contours minimum et maximum.

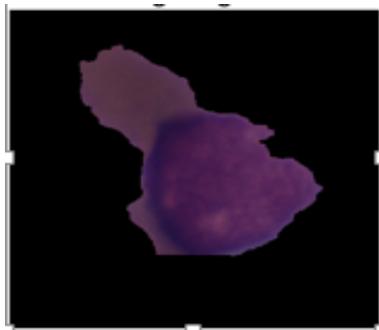
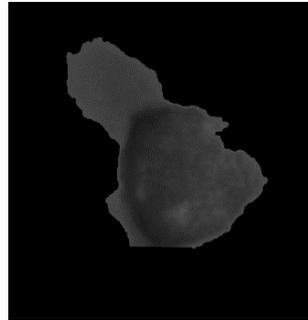


Image original



conversion en niveaux de gris



segmentation

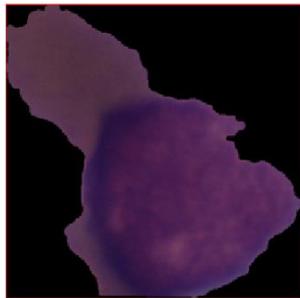
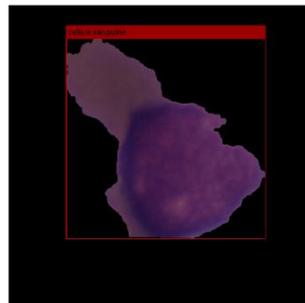
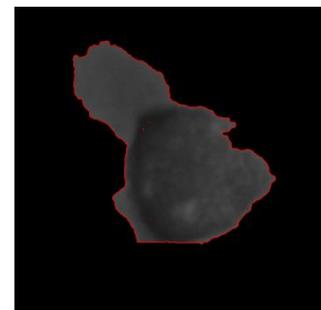


Image finale



Recadrer l'image



Détection de la cellule

Figure III. 4 : les étapes de prétraitement

III.3.2 Extraction des caractéristiques :

Les caractéristiques profondes sont obtenues à partir des modèles de réseaux de neurones convolutionnels (CNN). En d'autres termes, le modèle CNN est utilisé comme extracteur de caractéristiques pour alimenter les classificateurs tels que, les SVM, etc. En fonction de la structure du modèle et de sa hiérarchie, une couche peut être plus profonde que l'autre. Chacune des couches a des caractéristiques profondes, elles varient en fonction du filtre et des opérations mathématiques appliquées dans les couches et peuvent avoir des poids différents.

La figure III.5 montre comment envoyer une image à un réseau CNN et afficher les activations des différentes couches du réseau. En examinant les activations on peut découvrir quelles caractéristiques le réseau apprend en comparant les zones d'activation avec l'image d'origine. Les canaux des premières couches apprennent des caractéristiques simples telles que la couleur et les bords, tandis que les canaux des couches plus profondes apprennent des caractéristiques complexes.

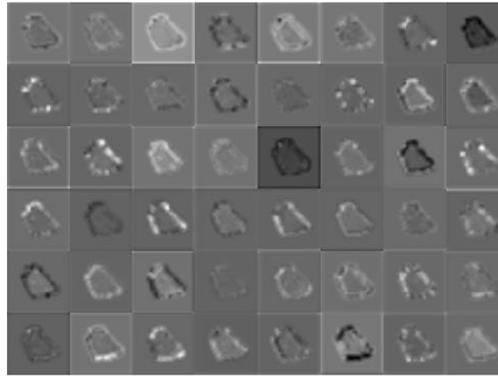
On s'attend à ce que les caractéristiques profondes représentent le plus haut niveau d'images d'objets destinés à être classifiés. Les noms des modèles CNN utilisés, les noms des couches pour extraire les caractéristiques et leurs nombres ainsi que la taille des images d'entrée sont indiqués sur le tableau III. 3

Les réseaux	Les couches	Nombre de caractéristique	La taille de l'image d'entrée
inceptionresnetV2	avg_pool	1536	299×299
Vgg19	Pool5	25088	224×224
densenet201	avg_pool	1920	224×224
mobilenetv2	global_average_pooling2d_1	1280	224×224
Resnet101	Pool5	2048	224×224
googlenet	Pool5-7×7_s1	1024	224×224
alexnet	fc6	4096	227×227

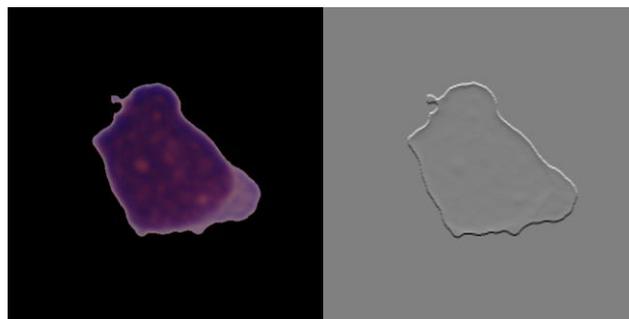
Tableau III.3 : les couches et le nombre de caractéristique des quelque réseaux utilisé



Interprétation visuelle de la carte des caractéristiques de la première couche de convolution



Interprétation visuelle de la carte des caractéristiques de la 6^{ième} couche de convolution



L'image originale (gauche) et visualisation du canal avec la plus grande activation (droite)

Figure III. 5 : Visualisation des caractéristiques les plus saillantes des couches de convolution et de pooling

III.3.3 Sélection des caractéristiques

Des groupes de caractéristiques réduits ont été obtenus en sélectionnant les caractéristiques plus distinctives parmi ceux obtenues à l'étape précédente. La sélection de caractéristiques importantes augmente le succès et diminue le nombre de paramètres utilisés, parce que

- les caractéristiques issues de l'extraction par CNN ne sont pas toutes également importantes
- les caractéristiques non importantes sont répétées plus d'une fois par différents réseaux.

Dans cette étape, les caractéristiques importantes sont sélectionnées à l'aide d'algorithmes Relief. Étant donné que le nombre d'entités à sélectionner est un hyper-paramètre, les tailles des vecteurs d'entités ont été modifiées de manière itérative pour obtenir le meilleur résultat (figure III 7).

L'idée clé de Relief [42] présenté à la figure III 6, est d'estimer la qualité des caractéristiques d'après la capacité de leurs valeurs à distinguer entre les instances (échantillons) qui sont proches les unes des autres. Pour cela, étant donnée une instance R_i (ligne 3) sélectionnée aléatoirement, Relief recherche pour cette instance deux plus proches voisins, une de la même classe que R_i appelé *hit* H , est l'autre de la classe différente appelé *miss* M (ligne 4), et met à jour l'estimation de la qualité $W[A]$ de chaque attribut A selon leur valeur pour R_i , M et H (lignes 5 et 6). Si les instances R_i et H ont des valeurs différentes pour l'attribut A , alors l'attribut A sépare entre deux instances de la même classe ce qui est indésirable, donc on diminue l'estimation de la qualité $W[A]$. Si les instances R_i et M ont des valeurs différentes pour l'attribut A , alors l'attribut A sépare entre deux instances de classes différentes, ce qui est désirable, donc on augmente l'estimation de la qualité $W[A]$. Le processus est répété m fois tel que m est un paramètre prédéfini par l'utilisateur.

➤ **L'algorithme Relief :**

L'algorithme Relief

Entrée : Ensemble de N instances, pour chaque instance, le vecteur des valeurs d'attributs et sa classe.

Sortie : Le vecteur W des estimations des qualités (poids) d'attributs.

1. Initialisation des poids $W[A] := 0$;

2. Pour $i := 1$ à m faire début

3. Sélectionner une instance R_i

4. Trouver le plus proche voisin de la même classe que R_i : H

5. Trouver le plus proche voisin de la classe différente R_i : M

6. Pour $A := 1$ à a faire

7. $W[A] - \text{diff}(A, R_i, H)/m + \text{diff}(A, R_i, M)/m$

8. fin

Figure III. 6: Pseudo code de l'algorithme Relief de base

La fonction $\text{diff}(A, I_1, I_2)$ calcule la différence entre les valeurs de l'attribut A pour les deux instances I_1, I_2 , pour les attributs symboliques elle est définie par:

$$\text{diff}(A, I_1, I_2) = \begin{cases} 0: \text{valeur}(A, I_1) = \text{valeur}(A, I_2) \\ 1: \text{autrement} \end{cases} \quad (\text{III.1})$$

Pour les attributs numériques Elle est définie par:

$$diff(A, I_1, I_2) = \frac{|valeur(A, I_1) - valeur(A, I_2)|}{\max(A) - \min(A)} \tag{III.2}$$

max (resp, min) désignent la valeur maximale (resp.minimale) que peut prendre l'attribut A, sur l'ensemble des données

La fonction diff est aussi utilisée pour calculer la distance entre les instances pour la recherche des plus proches voisins la distance total est simplement la somme des distance sur tous les attribus

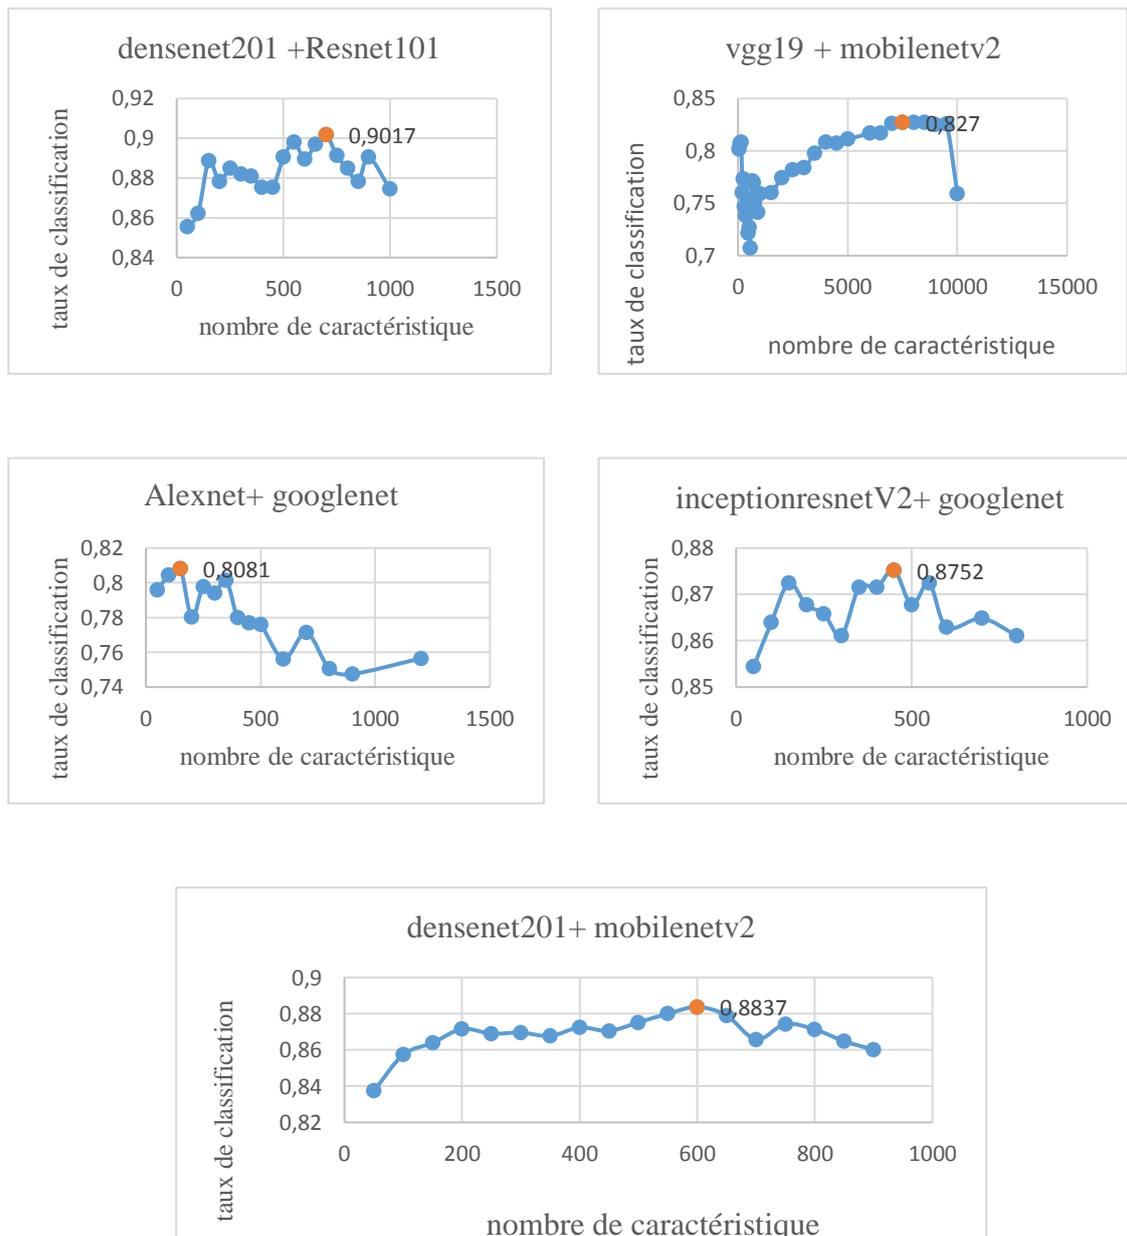


Figure III.7 : les caractéristiques importantes sont sélectionnées à l'aide d'algorithmes Relief.

III.5. Classification

Nous avons testé 5 combinaisons de fusion de caractéristiques pour évaluer le système proposé. Les caractéristiques fusionnées ont été attribuées en tant que données de d'entraînement (*trainings*) et de test (*testing*) en utilisant 5 validations croisées. Dans la première étape, les méthodes de classification ont été entraînées avec les données d'entraînement fusionnées. Ensuite, les données de test ont été transmises au classificateur pour mesurer la précision

Une méthode de classification est nécessaire pour déterminer les données de différentes classes dans l'ensemble de données étudié. Un procédé de classification utilise un algorithme d'apprentissage pour définir le modèle qui correspond le mieux à la relation entre l'ensemble de caractéristiques des données d'entrée et la classe.

Dans le cadre de cette étude, les caractéristiques sélectionnées et fusionnées des modèles CNN ont été classées en utilisant le classificateur SVM.

Les résultats et les performances des modèles utilisé pour classer les images en classe ALL et HEM sont donnés dur le tableau III 4 le tableau III 5 donne les résultats de la fusion des modelés CNN sans faire la sélection des caractéristiques et dans le tableau III 6 les même modelés avec sélection des caractéristiques

Nous avons choisi les meilleurs modèles en terme du taux de classification pour examiner et évaluer les résultats en calculant la matrice de confusion et de la courbe ROC

Les réseaux	Taux de classification
inceptionresnetV2	0.8724
Vgg19	0.8299
densenet201	0.8686
mobilenetv2	0.8374
Resnet101	0.8601
googlenet	0.8081
alexnet	0.8129

Tableau III.4 : taux de classification des réseaux utilisés

Les réseaux	Taux de classification	Le nombre total de caractéristique
vgg19 + mobilenetv2	0.8233	26368
Alexnet+ googlenet	0.8006	5120
inceptionresnetV2+ googlenet	0.8422	2560
densenet201 +Resnet101	0.8960	3958
densenet201+ mobilenetv2	0.8847	3200

Tableau III.5: taux de classification et le nombre total des caractéristiques

Les réseaux	Nombre de caractéristique	Taux de classification
vgg19 + mobilenetv2	7500	0.8270
Alexnet+ googlenet	150	0.8081
inceptionresnetV2+ googlenet	450	0.8752
densenet201 +Resnet101	700	0.9017
densenet201+ mobilenetv2	600	0.8837

Tableau III.6 : le taux de classification et le nombre de caractéristiques sélectionnées par Relief

✓ densenet201+ mobilenetv2

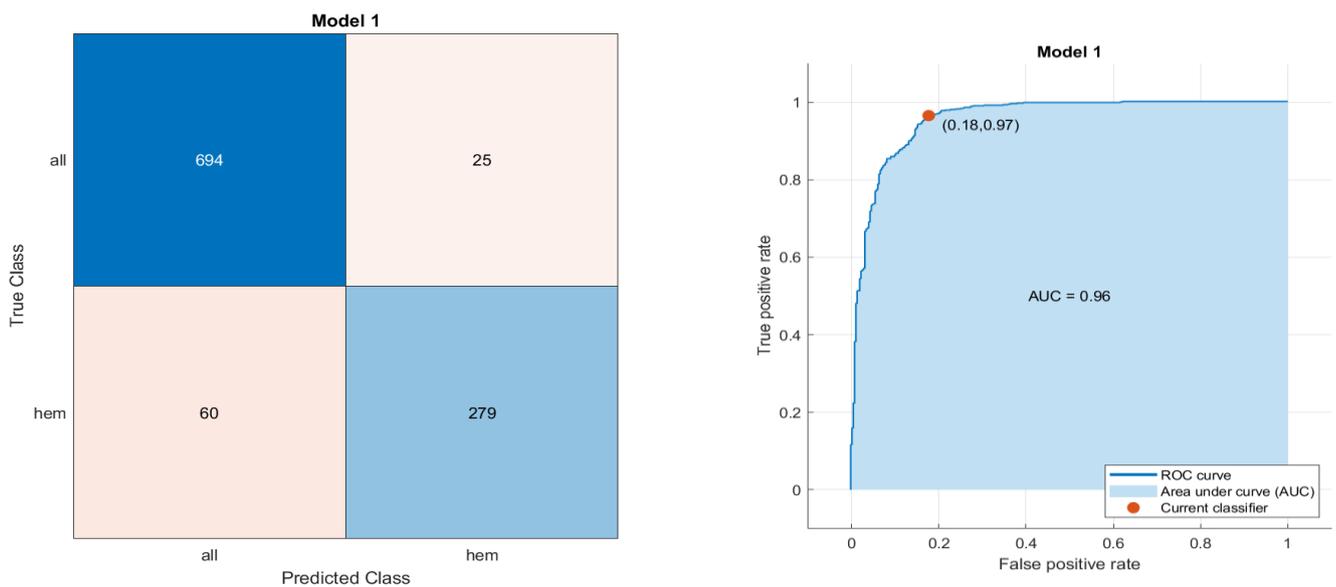


Figure III. 8 : La matrice de confusion et La courbe ROC d'un densenet201+ mobilenetv2

✓ densenet201 +Resnet101

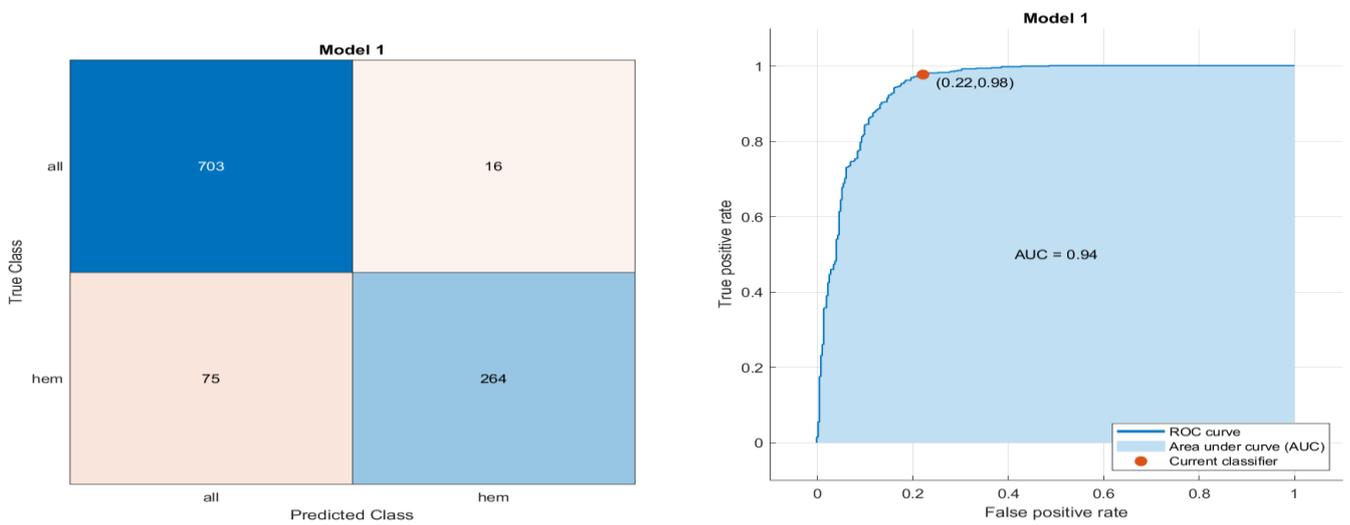


Figure III. 9 : La matrice de confusion et La courbe ROC d'un densenet201 +Resnet101

✓ inceptionresnetV2+ googlenet

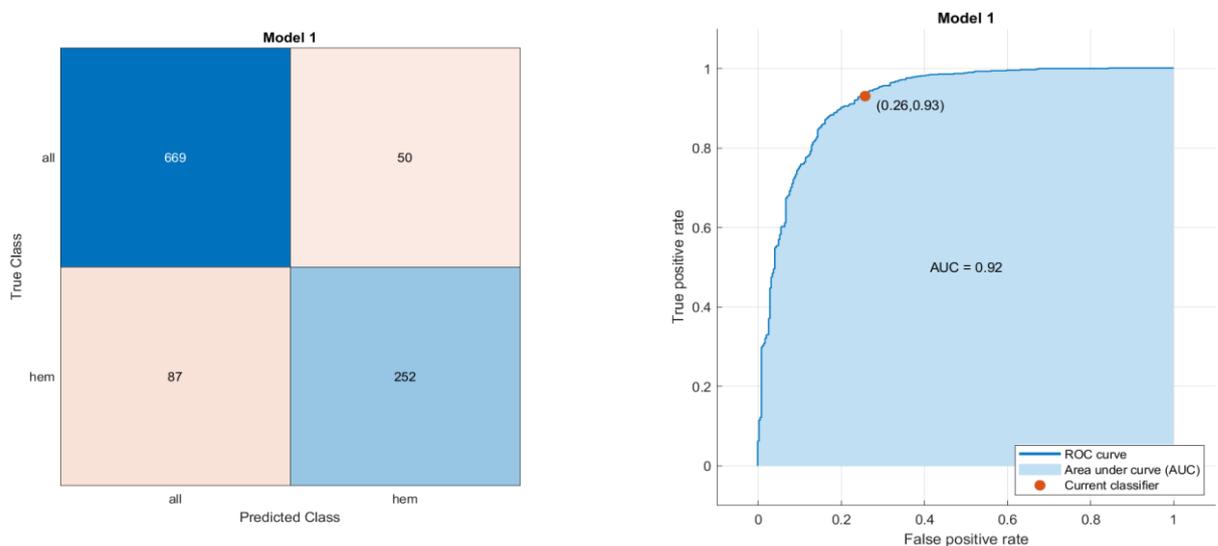


Figure III. 10 : La matrice de confusion et La courbe ROC d'un inceptionresnetV2+ Google net

D'après les résultats précédents, nous pouvons conclure les remarques suivantes

- en premier temps nous avons exploité les réseaux pré-entraînés pour extraire les caractéristiques, et classer les images ensuite par SVM, les résultats du tableau III 4 montrent que le réseau inceptionresnetV2 atteint le meilleur taux de classification avec 87,24%

- nous avons essayé différentes combinaisons de réseaux en utilisant la fusion des caractéristiques, nous avons obtenu une amélioration du taux notamment avec la fusion issue du densenet201+Resnet101 avec un taux de 89,60% et 3958 caractéristiques
- nous avons appliqué la sélection des caractéristiques en utilisant l'algorithme Relief pour éliminer les caractéristiques non pertinentes et redondantes, cela a fait améliorer le taux de classification d'un côté et alléger l'entraînement du classifieur SVM en prenant que les caractéristiques sélectionnées. Dans ce cas, la fusion densenet201+Resnet101 a dépassé les autres méthodes avec un taux de classification de 90,17% et le nombre de caractéristiques réduit de 3958 à 700.

III.6 Conclusion

Dans ce chapitre nous avons présenté une approche de classification basée sur l'extraction des caractéristiques par réseaux CNN pré-entraînés afin de classer les images de la leucémie ALL. Nous avons appliqué la sélection des caractéristiques pour garder les plus discriminantes et alléger les calculs lors de l'entraînement du classifieur SVM. Les résultats obtenus sont satisfaisants en terme des matrices de confusion et des courbes ROC et avec un taux plus de 90% .

Conclusion générale

Conclusion générale

Effectivement, à l'heure actuelle, notre société devient de plus en plus intelligente et le domaine de la classification d'images a connu une évolution majeure grâce au deep learning.

Les réseaux de neurones convolutionnels ont joué un rôle essentiel en éliminant la nécessité d'une extraction manuelle des caractéristiques, une tâche souvent fastidieuse. Ces réseaux sont capables d'apprendre par eux-mêmes les caractéristiques en s'entraînant sur des images, sans avoir besoin d'une préparation préalable.

Dans cette recherche, nous proposons une méthode automatisée pour détecter les lymphoblastes (cellules blastiques) dans des images individuelles afin d'aider à diagnostiquer la leucémie. Nous avons utilisé l'ensemble de données C_NMC_2019 pour l'entraînement.

Notre approche repose sur l'utilisation des réseaux de neurones convolutionnels pour une classification binaire : la classe positive (présence de cancer ALL) et la classe négative (absence de cancer HEM).

Nous avons discuté des principes fondamentaux de l'apprentissage automatique, des réseaux de neurones en général et plus spécifiquement des réseaux de neurones convolutionnels. Nous avons présenté les différentes couches utilisées dans la classification, telles que la couche de convolution, la couche d'activation, la couche de pooling et la couche fully connected.

En combinant l'extraction des caractéristiques par CNN et la classification par SVM, nous sommes en mesure d'obtenir un système performant pour la reconnaissance d'images. Le CNN capture les informations pertinentes de l'image, tandis que le SVM réalise une classification précise en utilisant ces caractéristiques. Cette approche permet d'obtenir des résultats précis et fiables dans la classification d'images. Nous avons amélioré les résultats en appliquant la sélection des caractéristiques discriminantes par l'algorithme Relief ce qui nous a donné un système plus performant et plus rapide

En perspective, nous proposons la conception d'un réseau CNN spécialement pour la classification de cette base de données cela veut dire entraîner à zéro le réseau avec les images leucémiques.

Références bibliographiques

Référence bibliographiques

- [1] Cho.S Tromburg et al,"Social adjustment across the lifespan in survivors of pediatric acute lymphoblastic leucémie (ALL) A systematic review", pp 1–17,2022
- [2] P.Rastogi et al, "Deep learning–based feature extractor for the diagnosis of acute leucémie from mi-croscopic images of peripheral blood smear", Comput Biol.Med 19, 105236,2022
- [3] A.Nono Djotsa et al, "Assessing Smoking Status and Risk of SARS-CoV-2 Infection: A Machine Learning Approach among Veterans. Healthcare ", pp 10 -1244, 2022
- [4] D. S. Team, "apprentissage automatique ? Une définition " , DATA SCIENCE ,déc 2020,
[En ligne], Disponible sur : <https://datascience.eu/fr/apprentissage-automatique/quest-ce-que-lapprentissage-automatique-une-definition>
- [5] A. F, " Computer Vision : définition, fonctionnement, cas d’usage, formations Devenir Data Scientist " ,Devenir Data Scientist, ,<https://www.jeuxetredatascientist.fr/computer-vision/>,
9mars 2023
- [6] N Bibi et al," IoMT-Based Automated Détection and Classification of Leukemia Using Deep Learning", Journal of Healthcare Engineering,pp 1-12 , 2020
- [7] Hoffbrand et al Essential Haematology. Wiley, New Jersey, USA, 6 edition,2013.
- [8] S,Mishra et al., "Texture feature based classification on microscopic blood smear for acute lymphoblastic leukemia detection", Biomedical Signal Processing and Control, vol.47, pp 303–311,2019
- [9] Z.Moshavash et al, "An automatic and robust decision support system for accurate acute leukemia diagnosis from blood microscopic images". Journal of Digital Imaging, vol 31,
pp 702–717,2018
- [10] A.Zerougui ,N. Sari , "Traitement d’images monochromes Détection de contours, Filtrage Spatial et fréquentiel et Segmentation par Réseaux de Neurones ", Mémoire de Master Informatique Industrielle, Département de Génie Electrique ,Université Larbi Ben M’hidi Oum El Bouaghi, Juin 2017

- [11] C. Garcia-Montero, " Computer vision définition et applications de la vision par ordinateur", www.journaldunet.fr, mars 2023, [En ligne]. Disponible sur, <https://www.journaldunet.fr/web-tech/dictionnaire-de-l-iot/1489513-computer-vision-definition-et-applications-de-la-vision-par-ordinateur>
- [12] D. de Ridder et al, " Pattern recognition in bioinformatics,Briegs in Bioinformatics", vol. 14, pp. 633 - 647, 2013
- [13] J.-P. Cocquerez And S. Philipp, "Analyse d'Images : filtrage et segmentation", Masson ,1995
- [14] M.Meliani, "Segmentation d'Image par Coopération Régions-Contours", Thèse de magister,Ecole nationale Supérieure en Informatique, Oued-SmarAlger, Ecole Doctorale STIC,2012
- [15] A.MEZIANE , "étude et comparaison des méthodes de segmentation d'image Cérébrales",Thèse de magister, Université Abou-Bakr Belkaid-Tlemcen,2011
- [16] K .Anilkumar et al, "A survey on image segmentation of blood and bone marrow smear images with emphasis to automated detection of Leukemia. Biocybernetics and Biomedical Engineering", Vol.40, Issue 4, pp 1406-1420, 2020.
- [17] M. Zolfaghari , H. Sajedi, "A survey on automated detection and classification of acute leukemia and WBCs in microscopic blood cells, " Multimedia Tools and Applications, Jan. 2022
- [18] S.Belmerabet ,N ,Bardjak , "Segmentation d'image ", Mémoire de MASTER Informatique des Vision artificielle, Département des Mathématiques et Informatique Université Larbi Ben M'hidi Oum El Bouaghi, 2017
- [19]A.AGGOUN, "Etude Comparative Entre Les Méthodes De Binarisation Des Images",MÉMOIRE Pourl'obtention dediplômeMaster en informatique, Département d'informatique et mathématique, Université Larbi Ben M'Hidi Oum El Bouaghi, 2019
- [20] U.Akilandeswari, R.Nithya,et B.Santhi, "Review on feature extraction methods in pattern classification. European", Journal of Scientific Research,vol 71, pp265-272,2012
- [21] M.Tuceryan,"JainTexture analysis. Handbook of pattern recognition andcomputer vision",vol 2, pp.207-248,1993.

- [22] L.Boldú et al,"Automatic recognition of different types of acute leukaemia in peripheral blood by image analysis",J Clin Pathol ,2019.
- [23] O. BENSIAH , "la proposition d'un nouvelle approche basée deep learning pour la prédiction du cancer du sein " , Mémoire de fin d'étude en vue de l'obtention du diplôme de Master En Informatique, Département Mathématiques Et Informatique, Université L'arbi Ben M'hidi Oum El Bouaghi, 2020
- [24] A.Crochet-Damais, Apprentissage supervisé définition et exemples d'algorithme www.journaldunet.fr févr2022[En ligne], Disponible sur :<https://www.journaldunet.fr/web-tech/guide-de-l-intelligence-artificielle/1501311-apprentissage-supervise>
- [25] G. Moll, "Apprentissage automatique et biais : Impacts et solutions - IBMFrance" IBM-France, <https://www.ibm.com/blogs/ibm-france/2019/09/26/apprentissage-automatique-et-biais/>
- [26] Data Analytics Post, "Apprentissage par renforcement - Data Analytics Post " ,Data Analytics Post, 6 juin 2017, <https://dataanalyticspost.com/Lexique/apprentissage-par-renforcement/>
- [27]"5 Types of Classification Algorithms in Machine Learning " , MonkeyLearn Blog <https://monkeylearn.com/blog/classification-algorithms/>,26 mars 2023.
- [28] H . Hilali , " application de la classification textuelle pour l'extraction des règles d'association maximales " , thèse de maitrise en informatique , université du québec , trois-rivières , 2009.
- [29] A.LABIAD , "sélection des mots clés basée sur la classification et l'exitraction des règles d'association",comme exigence partielle de la maitrise en mathématiques et informatique appliquées, université du québec,juin 2017.
- [30] Ubkov, " Comment lire une courbe ROC et interpréter son AUC " ,IDBC [En ligne]. Disponible sur : <https://www.idbc.fr/tutoriel-comment-lire-une-courbe-roc-et-interpreter-son-auc/>,juill. 2021.
- [31] M.Boughaba ,B.Boukhris, "L'apprentissage profond (Deep Learning) pour la classification et la recherche d'images par le contenu " , Thèse de master: University Kasdi Merbah , Ouargla ,2017.
- [32] M.Ounissi , Z.Harnane , "Modélisation et classification avec Deep Learning Application à la détection du Coronavirus Covid-19", Master Académique, Electronique des systèmes embarqués

, Département de Génie Electrique, Université Mohamed Larbi Ben M'hidi - Oum El bouaghi, 2020

[33] H.Wang et al, "On the origin of deep learning ", arXiv preprint arXiv 1702.07800, 2017

[34] J.F. Jodouin, "Les réseaux de neurones. Principes et définitions", édition Hermis, Paris, 1994.

[35] Rod, "Comprendre les réseaux de neurones - MonCoachData " ,MonCoachData ,
. <https://moncoachdata.com/blog/comprendre-les-reseaux-de-neurones/>

[36] S. Nedjaoume , " Entraînement D'un Réseau De Neurones MLPPar La Méthode BFGS", thèse de master : Université Larbi Ben m'hidi Oum el Bouaghi 2016.

[37] D.Mechaheb ,A.Hammache, "Répartition économique de l'énergie électrique à l'aide de la technique des réseaux de neurones artificiels ", Thèse de master Université Abderrahmane Mira de Bejaïa , 2013.

[38] C. Aggarwal, "Neural Networks and Deep Learning ", IBM T. J. Watson Research Center International Business Machines, Yorktown Heights, NY, USA

[39] Y. Djeriri , " Les Réseaux de Neurones Artificiels" ,septembre 2017

[40] D. Rumelhart et al, " Learning internal representations by error propagation. ", In Parallel distributed processing Explorations in the microstructure of cognition, Vol. 1: Foundations. MIT Press, 1986

[41] T. Rédac, " Convolutional Neural Network Tout ce qu'il y a à savoir " ,Formation Data Science DataScientest.com ,<https://datascientest.com/convolutional-neural-network> , 20 juin 2023.

[42]N. Houacine , N.Khelifa , " Classification des textures par les réseaux de neurones convolutif ", thèse master academique , Spécialité : Commande des systèmes, departement d'automatique ,université mouloud mammeri de tizi-ouzou,2018

[43] Z.Mokri , " Classification des images avec les réseaux de neurones convolutionnels", Mémoire de fin d'études Pour l'obtention du diplôme de Master en informatique, Département D'informatique, Université Abou Bakr Belkaid Tlemcen, 2017

- [44] H.Sekkil , M MEBROUKI , " Etude comparative entre les différentes architectures des réseaux de neurones convolutifs (CNNs) pour la détection de la fatigue du conducteur ", Mémoire de Master Automatique, Département Automatique, higher school in applied sciences tlemcen, 2021
- [45] B.Habib, "les réseaux de neurones convolutifs", <https://datasciencetoday.net/index.php/fr/deep-learning/173-les-reseaux-de-neurones-convolutifs> , 16 février 2023
- [46] S. Madeleine, "Deep learning : les réseaux de neurones convolutifs pour la classification d'images médicales " <https://www.imaios.com/fr/ressources/blog/classification-des-images-medicales-comprendre-le-reseau-de-neurones-convolutifs-cnn>, IMAIOS , 16 février 2023
- [47] M. Mokri , " Classification des images avec les réseaux de neurones convolutionnels ", Pour l'obtention du diplôme de Master en informatique, Département D'informatique, université d'Oum El Bouaghi , 2017
- [48] Y. LeCun, et al, "Gradient-based learning applied to document recognition," Proceedings of the IEEE, vol. 86, pp. 2278-2324, 1998.
- [49] A. Krizhevsky, et al, "Imagenet classification with deep convolutional neural networks," in Advances in neural information processing systems, pp. 1097-1105, 2021.
- [50] C. Szegedy, et al, "Going deeper with convolutions," in Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 1-9, 2015.
- [51] K. He, et al, "Deep residual learning for image recognition," in Proceedings of the IEEE conference on computer vision and pattern recognition, 2016, pp. 770-778.
- [52] S. Shadman et al, "An Overview of Convolutional Neural Network Its Architecture and Application", of EEE, International University of Business Agriculture and Technology, Dhaka 1230, Bangladesh
- [53] SBILab. Signal Processing and Biomedical Imaging Lab, 2022, Available online: <http://sbilab.iiitd.edu.in/> , accessed on 8 June 2023.
- [54] S. Mourya et al, ALL Challenge Dataset of ISBI. 2019. Available online: <https://wiki.cancerimagingarchive.net/x/zwYlAw> , accessed on 8 June 2023.

- [55] D. Lightweight et al, "Classification of Normal Versus Leukemic Cells Using Feature Extraction. In Proceedings of the 2021 IEEE Symposium on Computers and Communications (ISCC), Athens, Greece, pp. 1–7, 2021
- [56] C. Marzahl et al, " Classification of Leukemic B-Lymphoblast Cells from Blood Smear Microscopic Images with an Attention-Based Deep Learning Method and Advanced Augmentation Techniques" ., In Lecture Notes in Bioengineering; Springer Singapore, pp. 13–22, 2019
- [57] R. Gupta. et al, " Stain Color Normalization and Segmentation of Plasma Cells in Microscopic Images as a Prelude to Development of Computer Assisted Automated Disease Diagnostic Tool in Multiple Myeloma ", 17, e99, Clin. Lymphoma Myeloma Leuk. 2017
- [58] R. Duggal et al, "Overlapping cell nuclei segmentation in microscopic images using deep belief networks. In Proceedings of the Tenth Indian Conference on Computer Vision, Graphics and Image Processing (ICVGIP), Guwahati, India", pp 18–22, 2016
- [59] R. Duggal et al, "Stain Deconvolutional Layer for CNNs in Medical Microscopic Imaging. In Proceedings of the Medical Image Computing and Computer Assisted Intervention (MICCAI) ", Quebec City, QC, Canada, pp 11–13 , 2017

ملخص

في هذا العمل نقدم تصنيف صور لنسيج الدم للكشف السريع عن سرطان الدم الحاد لدى الأطفال (ALL) بالاعتماد على التعلم العميق حيث تم استخدام الشبكات العصبية التلافيفية (CNN) والمصنف SVM الذي يعد من أكثر الطرق كفاءة في مجال تصنيف الصور. انطلاقاً من قاعدة البيانات C-NMC 2019 تم استخراج الميزات من مختلف الشبكات العصبية التلافيفية (CNN) فأظهرت أداء مقبول. ومن أجل تحسين النتائج قمنا بدمج عدة شبكات عصبية تلافيفية فكانت نتائج التصنيف جيدة. ومن جهة أخرى قمنا باختيار الميزات الأكثر أهمية عن طريق خوارزمية Relief حيث نتج عن ذلك تحسين النتائج من خلال مراقبة مصفوفة التشتت ومنحنى ROC والحصول على نموذج أبسط للتصنيف.

Résumé

Dans ce travail, nous présentons une classification des images de tissu sanguin pour la détection rapide de la leucémie aiguë chez l'enfant (ALL) basée sur l'apprentissage profond, où les réseaux de neurones convolutionnels (CNN) et le classificateur SVM ont été utilisés, qui est l'une des méthodes les plus efficaces dans le domaine de la classification d'images. Basé sur la base de données C-NMC 2019, les caractéristiques ont été extraites de divers réseaux de neurones convolutionnels (CNN) et ont montré des performances acceptables. Afin d'améliorer les résultats, nous avons fusionné plusieurs réseaux de neurones convolutionnels, D'autre part, nous avons sélectionné les caractéristiques les plus importantes via l'algorithme Relief, cela a permis d'améliorer les résultats en terme de la matrice de confusion et la courbe ROC, et d'obtenir un modèle de classification plus simple.

Abstract

In this work, we present a classification of blood tissue images for rapid detection of childhood acute leukemia (ALL) based on deep learning, where convolutional neural networks (CNN) and SVM classifier were used, which is one of the most effective methods in the field of image classification. Based on C-NMC 2019 database, features were extracted from various convolutional neural networks (CNN) and showed acceptable performance. In order to improve the results, we merged several convolutional neural networks, On the other hand, we selected the most important features via the Relief algorithm, this made it possible to improve the results in terms of the confusion matrix and the ROC curve, and to obtain a simpler classification model.