



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

**UNIVERSITE IBN KHALDOUN - TIARET**

# **MEMOIRE**

Présenté à :

**FACULTÉ MATHÉMATIQUES ET  
INFORMATIQUE DÉPARTEMENT  
D'INFORMATIQUE**

Pour l'obtention du diplôme de :

**MASTER**

**Spécialité : Génie Informatique**

Par :

**NOUKAS OUM-HANI**

Sur le thème

---

***Etude Comparative des CNNs et de L'algorithme K-NN en  
mammographie***

---

Soutenu publiquement le ... /07/ 2023 à Tiaret devant le jury composé de :

Mr ZIOUAL TAHAR	Grade M.A.A	Université Tiaret	Président
Mr CHENINE Abdelkader	Grade M.A.A	Université Tiaret	Encadrant
Mr BERBER ELMEHDI	Grade M.A.A	Université Tiaret	Examineur

**2022-2023**

## Dédicace

*C'est avec une très grande émotion que je dédie ce modeste travail à mes très chers parents :*

*« Rabeh et Khaira » source de mon existence, qui m'ont accompagné durant tout mon parcours, je dédie à ma chère Grand-mère, je leur dis MERCI pour votre soutien, que Dieu les protège.*

*A mes chers frères Amine, Abd Elhak, Rafik, Mourad, Khaled et Mustapha*

*A ma très chère sœur : Fatima et son mari Abd Elillah et leur prochaine fille Assénatt*

*A toutes les familles Noukas, Dehli, Kebah, Kasem , Ghallel*

*A Toutes mes amies et particulièrement Lilia Fellah, Kind Mhloule, Sara Soukri, B Khadija,  
M Fatima et O Sabina*

*A mon promoteur Mr CHENINE Abdelkader*

*A toutes les personnes qui ont contribué de près ou de loin à l'élaboration de ce mémoire.*

*Noukas Oum-Hani*

## *Remerciement*

*En premier lieu, nous remercions ALLAH, Le Tout Puissant et Miséricordieux, qui nous a donné la force, le courage et la patience d'accomplir ce modeste travail.*

*Nos remerciements et nos profondes gratitudes vont à notre encadrant Monsieur CHENINE Abdelkader pour ses précieux conseils et pour tout le soutien et l'orientation; et d'avoir bien voulu diriger notre travail, et d'avoir donné le meilleur de son savoir et de son aide, et surtout d'avoir fait preuve de beaucoup de patience, son aide durant toute la période du travail.*

*Nous tenons aussi à remercier les membres du jury pour leur précieux temps accordé à l'étude de notre mémoire.*

*Nous remercions nos enseignants pour leurs efforts, nos parents et nos proches pour l'amour et le soutien constant qu'ils nous ont témoigné tout au long de notre parcours. Merci à toutes et tous nos ami (e)s pour leurs encouragements.*

## Résumé

Dans ce projet, nous nous intéressons à la mammographie pour détecter les anomalies/tumeurs (l'objectif du projet est de mettre en œuvre un algorithme d'apprentissage profond (CNN) et l'algorithme d'apprentissage automatique (k-nn) nous permet de détecter des anomalies dans l'image mammographique. Afin d'atteindre notre objectif, nous avons étudié tous les algorithmes utilisés pour classer les images, nous avons sélectionné les plus importants et efficaces dans la littérature.

Pour les mettre en œuvre, nous avons utilisé des techniques d'apprentissage profond pour détecter les mammographies. Nous avons appliqué quatre modèles (vgg-16, vgg-19, mobilenet, densenet). Nous avons appliqué un modèle k-nn qui a obtenu des résultats et tous les résultats ont été comparés.

**Mots-clés :** Détection des tumeurs du sein, Imagerie par rayons, Deep Learning, Machine Learning, Mobilenet, Densenet, VGG-19, VGG-16, KNN, CNN.

## Abstract

In this project, we focus on mammography to detect abnormalities/tumors (the objective of the project is to implement a deep learning algorithm (cnn) and the machine learning algorithm (k-nn) allows us to detect anomalies in the mammographic image. In order to reach our goal, we studied all the algorithms used to classify images, we selected the most important and effective ones in the literature.

To implement them, we used deep learning techniques to detect mammograms. We applied four models (vgg-16, vgg-19, mobilenet, densenet). We applied a k-nn model which obtained results and all results were compared.

**Keywords:** Breast tumor detection, Ray imaging, Deep Learning, Machine Learning, Mobilenet, Densenet, VGG-19, VGG-16, KNN, CNN.

## ملخص

في هذا المشروع، نحن مهتمون بالتصوير الشعاعي للثدي لاكتشاف التشوهات/الأورام (الهدف من المشروع هو تنفيذ خوارزمية التعلم العميق (cnn) وخوارزمية التعلم الآلي (k-nn) تسمح لنا باكتشاف الشذوذ في صورة التصوير الشعاعي للثدي. من أجل الوصول إلى هدفنا، درسنا جميع الخوارزميات المستخدمة لتصنيف الصور، واخترنا أهمها وأكثرها فاعلية في الأدبيات.

لتنفيذها، استخدمنا تقنيات التعلم العميق لاكتشاف تصوير الثدي بالأشعة السينية. طبقنا أربعة نماذج (vgg-16 ، vgg-19 ، mobilenet ، densenet) طبقنا نموذج k-nn وتم مقارنة جميع النتائج.

**الكلمات الرئيسية:** اكتشاف ورم الثدي، تصوير الأشعة، التعلم العميق، التعلم الآلي، Densenet، Mobilenet، VGG-19 ، VGG-16 ، KNN، CNN.

# Sommaire

INTRODUCTION GENERALE .....	1
CHAPITRE I: L'INTELLIGENCE ARTIFICIELLE ET L'APPRENTISSAGE PROFOND.....	2
INTRODUCTION .....	2
I.1 L'INTELLIGENCE ARTIFICIELLE (IA) .....	2
I.1.1 <i>Sous-domaines de l'Intelligence Artificielle</i> .....	3
A. Apprentissage automatique (Machine Learning) .....	3
B. L'apprentissage profond (Deep Learning en anglais) .....	3
a. Les avantages de DL et pourquoi nous l'avons choisi plutôt que ML .....	4
I.2 L'APPRENTISSAGE PROFOND .....	5
I.2.1 <i>Histoire du L'apprentissage profond</i> .....	5
I.2.2 <i>Définition</i> .....	6
I.2.3 <i>Domaines d'application du deep learning</i> .....	6
A. La reconnaissance faciale .....	7
B. La détection d'objets.....	7
C. Traductions .....	7
D. Conduite autonome.....	7
E. Robots industriels.....	7
I.2.4 <i>Principe de fonctionnement de l'apprentissage profond</i> .....	8
I.2.5 <i>Les types d'apprentissage profond</i> .....	9
A. Apprentissage supervisé .....	9
B. Apprentissage non supervisé.....	9
C. Apprentissage semi-supervisé (hybride) .....	9
I.3 RESEAUX DE NEURONES .....	10
I.3.1 <i>Qu'est-ce qu'un réseau de neurones ?</i> .....	10
I.3.2 <i>Neurone Biologique</i> .....	10
I.3.3 <i>Neurone Artificiel</i> .....	11
I.3.4 <i>L'Analogie Entre le Neurone Biologique et le Neurone Artificiel</i> .....	11
I.3.5 <i>Des réseaux neuronaux aux réseaux neuronaux profonds</i> .....	12
I.3.6 <i>Les types des réseaux de neurones profonds</i> .....	12
A. Le perceptron multi-couches (MLP).....	12
B. Réseau Feed Forward (FF).....	13
C. Réseau neuronal convolutif (CNN).....	14
D. Réseau neuronal récurrent (RNN).....	14
E. Mémoire à long et court terme (LSTM) .....	15
I.3.7 <i>Réseaux de Neurones Convolutifs (ConvNets/CNNs)</i> .....	15
I.3.8 <i>Le principe de Réseaux de neurones convolutifs</i> .....	17
I.3.9 <i>Types de couches dans le réseau neuronal convolutif</i> .....	17
A. Couche convolutive (Convolutional layer CONV) .....	18
B. Couche d'unité linéaire rectifiée (Rectified Linear Unit layer ReLU) .....	19
C. Couche de Pooling .....	19
I.4 ETAT DE L'ART.....	20
I.4.1 <i>Les Architectures de CNN</i> .....	20
A. LeNet-5.....	20
a. La structure LeNet-5 .....	21
B. AlexNet.....	21
a. Structure du réseau AlexNet .....	21
C. VGG-19 .....	22

D. GoogleNet .....	23
a. Applications de GoogLeNet .....	23
E. ResNet .....	24
F. FaceNet .....	24
G. DenseNet .....	24
H. U-NET : le réseau de neurones de Computer Vision .....	25
a. L'architecture de U-NET : .....	25
b. Les avantages de U-NET .....	26
c. Comment apprendre à utiliser U-NET ? .....	27
d. Comprendre le fonctionnement de U-Net .....	27
I. Modèle YOLO .....	28
I.4.2 Avantages de CNNs .....	29
I.4.3 Les inconvénients des réseaux de neurones à convolution (CNN) : .....	29
I.5 FONCTION D'ACTIVATION .....	30
I.5.1 Fonction sigmoïde .....	30
I.5.2 Fonction de Relu .....	30
conclusion .....	31
<b>CHAPITRE II: GENERALITES SUR L'APPRENTISSAGE AUTOMATIQUE</b> .....	<b>33</b>
II.1 DEFINITION .....	33
II.2 LES ALGORITHMES DE L'APPRENTISSAGE AUTOMATIQUE UTILISES .....	34
II.2.1 Apprentissage supervisé .....	34
II.2.2 Apprentissage non supervisé .....	34
A. Knearest neighbors (KNN) .....	35
a. Algorithme de construction de KNN .....	35
b. L'algorithme KNN .....	36
c. Avantage de KNN .....	37
d. Inconvénients de KNN .....	37
B. Random Forest (forêts aléatoires) .....	37
a. Avantage de Random forest .....	38
b. Inconvénient de Random forest .....	38
C. Support Vector Machine (SVM) .....	38
a. Avantage de SVM .....	39
b. Inconvénient de SVM .....	39
D. Naïve_Bayes .....	39
a. Théorème de bayes .....	40
b. Avantage de naïve Bayes .....	40
c. Inconvénient de naïve Bayes .....	40
conclusion .....	40
<b>CHAPITRE III: TRAITEMENT D'IMAGE</b> .....	<b>42</b>
III.1 RAPPELS SUR LA NOTION D'IMAGE .....	42
III.2 DEFINITION DE L'IMAGE .....	42
III.2.1 Image binaire .....	42
III.2.2 Image en niveaux de gris .....	43
III.2.3 Image couleur (RGB) .....	43
III.2.4 Image indexée .....	43
III.3 CARACTERISTIQUES DE L'IMAGE NUMERIQUE .....	43
III.3.1 Pixel .....	44
III.3.2 Définition de l'histogramme .....	44
III.3.3 Contours et textures .....	45

III.3.4 Dimension.....	45
III.3.5 Bruit .....	45
III.3.6 Luminance .....	45
III.3.7 Contraste.....	46
III.3.8 Région .....	46
III.3.9 Connexité.....	46
III.4 LA SEGMENTATION D'IMAGE.....	46
III.4.1 Définition de la segmentation d'images.....	47
III.4.2 les approches de segmentation .....	47
A. Approches contour.....	48
a. Définition.....	48
B. Approche région .....	49
a. Segmentation par fusion de régions (MERGE).....	49
b. Segmentation par division de régions (SPLIT) .....	50
C. Segmentation par division-fusion (SPLIT+Merge).....	50
III.4.3 Les inconvénients de cette méthode se situent à trois niveaux .....	51
III.5 QUELQUES ALGORITHMES DE SEGMENTATION D'IMAGES .....	51
III.5.1 Algorithmes de classification de pixels non-supervisée :[33].....	51
a. L'algorithme des k-moyennes. ....	51
b. L'algorithme des C-moyennes floues.....	51
c. L'algorithme de Fisher .....	51
III.5.2 Algorithmes de classification de pixels supervisée .....	51
a. Algorithme des k-plus proches voisins. ....	51
b. Algorithme de Bayes. ....	51
c. Algorithme des Machines à support de vecteurs. ....	51
d. Algorithme des Réseaux de Neurones Multi Couches. ....	51
III.6 OBJECTIFS DE LA SEGMENTATION.....	51
III.7 SEGMENTATION SEMANTIQUE D'IMAGES .....	52
III.8 LA CLASSIFICATION D'IMAGE .....	52
III.8.1 Méthodes de classification d'images .....	52
III.8.2 L'objectif de la classification .....	52
III.8.3 Domaines d'application de la classification .....	53
conclusion.....	54
CHAPITRE IV: GENERALITES SUR LE CANCER DU SEIN .....	56
IV.1 DEFINITION .....	56
IV.2 LES CARACTERISTIQUES DU CANCER DU SEIN .....	57
IV.3 CLASSIFICATION DE CANCER DE SIEN .....	58
IV.3.1 Classification Clinique .....	58
IV.3.2 La classification histopathologies du cancer du sein.....	59
IV.3.3 la classification moléculaire du cancer du sein .....	59
IV.4 LES TYPES DE CANCER DU SEIN.....	60
IV.4.1 Le cancer in Situ .....	60
A. Carcinome canalaire in situ (intra canalair) .....	61
B. Carcinome lobulaire in situ (intra lobulaire).....	61
IV.4.2 Le cancer Infiltrant.....	61
A. Les masses.....	62
IV.5 EPIDEMIOLOGIE DU CANCER DE SEIN .....	62
IV.5.1 Indice et mortalité.....	62
A. Dans le monde .....	62

B. En Algérie.....	64
IV.5.2 <i>Survie</i> .....	65
IV.6 FACTEURS DES RISQUES DU CANCER DU SEIN.....	65
IV.6.1 <i>Facteurs des risques intrinsèques</i> .....	66
IV.6.2 <i>Facteurs de risques extrinsèques</i> .....	67
A. Obésité et prise de poids.....	67
B. Activité physique.....	67
C. Cigarette.....	67
D. Alcool.....	68
IV.7 DEPISTAGE DU CANCER DU SEIN.....	68
IV.8 LES SYMPTOMES DU CANCER DU SEIN.....	69
IV.9 DIAGNOSTIC DU CANCER DU SEIN.....	70
IV.9.1 <i>L'examen clinique</i> .....	70
IV.9.2 <i>Mammographie</i> .....	70
IV.9.3 <i>L'échographie mammaire</i> .....	70
IV.9.4 <i>Le scanner</i> .....	70
IV.9.5 <i>IRM (Imagerie par Résonance Magnétique)</i> .....	70
IV.9.6 <i>La biopsie</i> .....	70
IV.10 TRAITEMENT.....	71
A. Local.....	71
B. Evolué.....	71
IV.10.2 <i>Chirurgie</i> .....	71
a. La chirurgie tumorale.....	71
b. La chirurgie ganglionnaire.....	72
IV.10.3 <i>Radiothérapie</i> .....	72
IV.10.4 <i>Traitement systémique</i> .....	72
A. Chimiothérapie.....	73
B. Hormonothérapie.....	73
C. Thérapie ciblée.....	73
IV.10.5 <i>Traitement non systémique</i> .....	73
<i>conclusion</i> .....	74
CHAPITRE V: IMPLEMENTATION ET DISCUSSION DES RESULTATS.....	76
V.1 INTRODUCTION.....	76
V.2 OUTILS ET BIBLIOTHEQUES.....	76
V.2.1 <i>Python</i> :.....	76
V.2.2 <i>Google Colab</i> :.....	78
A. Avantages de Colab :.....	78
V.2.3 <i>Navigateur Anaconda</i> .....	79
V.2.4 <i>Jupyter Notebook</i> .....	79
V.2.5 <i>Google drive</i> :.....	79
V.3 DESCRIPTION DE LA BASE MIAS :.....	80
V.4 LE MODELE CNN (DEEP LEARNING) :.....	83
V.4.1 <i>Implémentation du modèle CNN</i> .....	83
V.4.2 <i>Résultats de modèle CNN</i> .....	85
A. VGG-16 :.....	86
B. VGG-19 :.....	86
C. MobileNet :.....	87
D. DenseNet :.....	87
V.4.3 <i>Comparaison entre les 04 modèles (VGG-16, VGG-19, MobileNet, DenseNet)</i> .....	88



V.5 LES MODELES DE MACHINE LEARNING : .....	89
V.5.1 <i>k plus proche voisins</i> .....	89
V.5.2 <i>Random Forest</i> .....	90
V.5.3 <i>DummyClassifier</i> .....	91
V.6 LA COMPARAISON DES ALGORITHMES K PLUS PROCHES VOISINS (KNN) ET DES MODELES CNN (VGG-16, VGG-19, DENSENET ET MOBILENET) EN MAMMOGRAPHIE.....	92
<i>conclusion</i> .....	93
<i>conclusion générale</i>	
<i>bibliographie</i>	

## Liste de Figure :

<b>Figure 1:</b> La relation entre l'intelligence artificielle, le ML et le deep learning .....	3
<b>Figure 2 :</b> La différence de performance entre le Deep Learning et la plupart des algorithmes de ML en fonction de la quantité de données.....	4
<b>Figure 3 :</b> Le procédé du ML classique comparé à celui du Deep Learning .....	5
<b>Figure 4:</b> Schéma d'un neurone ouvert. [10].....	8
<b>Figure 5:</b> Le neurone biologique [9].....	10
<b>Figure 6:</b> Neurone artificiel à entrées multiples [10].....	11
<b>Figure 7:</b> Les couches d'un perceptron multi-couches .....	13
<b>Figure 8:</b> Structure générale d'un réseau de neurones convolutifs .....	14
<b>Figure 9:</b> RNN exemple. ....	15
<b>Figure 10:</b> L'erreur top -5 % des architectures gagnantes de la compétition ILSVRC .....	16
<b>Figure 11:</b> Exemple de réseau composé de nombreuses couches à convolution. Des filtres sont appliqués à chaque image utilisée pour l'apprentissage à différentes résolutions, et la sortie de chaque image convoluée est utilisée comme entrée de la couche suivante. [16] .....	19
<b>Figure 12:</b> Exemple de fonctionnement de Max pooling et Average pooling.....	20
<b>Figure 13:</b> Histoire évolutive des CNNs montrant les innovations architecturales .....	20
<b>Figure 14:</b> La structure LeNet-5 proposée par Yann LeCun [16] .....	21
<b>Figure 15:</b> Exemple de CNN appelé AlexNet. ....	22
<b>Figure 16:</b> Architecture du modèle VGG-19.[18].....	23
<b>Figure 17:</b> réseau convolutifs le Resnet.....	24
<b>Figure 18:</b> L'architecture de Réseau entièrement convolutionnel U-Net pour une image $32 \times 32$ .....	26
<b>Figure 19:</b> YOLO model [22].....	29
<b>Figure 20:</b> histogramme de fonction sigmoïd.....	30
<b>Figure 21:</b> histogramme de fonction Relu .....	31
<b>Figure 22:</b> Quelques types de problèmes d'apprentissage automatique.....	34
<b>Figure 23:</b> Apprentissage supervisé.....	34
<b>Figure 24:</b> Exemple simple sur KNN .....	35
<b>Figure 25:</b> Structure de l'algorithme random forest [26].....	38
<b>Figure 26:</b> Un simple exemple sur le fonctionnement de l'algorithme SVM.....	39
<b>Figure 27:</b> Image couleur indexée. ....	43
<b>Figure 28:</b> représentation de pixel.[31].....	44
<b>Figure 29:</b> L'image comme un groupe de pixels. ....	44
<b>Figure 30 :</b> Histogramme d'image .....	45
<b>Figure 31:</b> Voisinages (a) 8-connexité (b) 4-connexité .....	46
<b>Figure 32:</b> Segmentation d'une image couleur.....	47
<b>Figure 33:</b> approche région et approche contour. ....	48
<b>Figure 34:</b> Profil de contours (marche, rampe, toit, pic).....	48
<b>Figure 35 :</b> Quelques modèles de contours.....	48
<b>Figure 36 :</b> Agrégation itérative des blocs similaires au bloc 1. ....	50
<b>Figure 37c:</b> schéma d'une vue latérale du sein.[39] .....	58
<b>Figure 38:</b> le sein Normal et le sein Anormal.....	62
<b>Figure 39 :</b> Les types de masses .....	62
<b>Figure 40:</b> Cancres féminins (mortalité, répartition mondiale) [45] .....	64
<b>Figure 41:</b> Evolution annuelle des fréquences du cancer du sein féminin RCO 1996-2016 .....	65
<b>Figure 42 :</b> Incidence et mortalité du cancer du sein par âge.....	66
<b>Figure 43:</b> Un diagramme schématique des facteurs de risque est représenté dans une structure.[47] 68	

<b>Figure 44</b> : Les types de chirurgies dans le cancer du sein.[52].....	71
<b>Figure 45</b> : La technique du ganglion sentinelle [52] .....	72
<b>Figure 46</b> : Google Colab .....	78
<b>Figure 47</b> : comment utiliser drive. ....	79
<b>Figure 48</b> : représente les classes de l'ensemble de données. ....	81
<b>Figure 49</b> : choisir l'accélération matériel .....	81
<b>Figure 50</b> : Importer les bibliothèques utilisées.....	82
<b>Figure 51</b> : installé le dataset (MIAS).....	82
<b>Figure 52</b> : Code de Division des données apprentissage/testes .....	82
<b>Figure 53</b> : Code de préparation importes les modèles CNN.....	83
<b>Figure 54</b> : Construction de modèle VGG-16.....	83
<b>Figure 55</b> : Construction de modèle VGG-19.....	84
<b>Figure 56</b> : Construction de modèle MobileNet .....	84
<b>Figure 57</b> : Construction de modèle DenseNet.....	84
<b>Figure 58</b> : compilation des modèles de CNN.....	84
<b>Figure 59</b> : Code d'affichage des résultats (précision, accuracy, racall,Auc,loss). ....	85
<b>Figure 60</b> : Code des tracés des courbes de modèle (précision et perte). ....	85
<b>Figure 61</b> : La courbe de perte (loss) et la courbe de précision (accuracy) de réseau VGG-16. ....	86
<b>Figure 62</b> : La courbe de perte (loss) et la courbe de précision (accuracy) de réseau VGG-19. ....	86
<b>Figure 63</b> : La courbe de perte (loss) et la courbe de précision (accuracy) de réseau MonileNet .....	87
<b>Figure 64</b> : La courbe de perte (loss) et la courbe de précision (accuracy) de réseau DenseNet.....	87
<b>Figure 65</b> : L'histogramme de la Comparaison entre les déférents modèles de CNN.....	88
<b>Figure 66</b> : la Comparaison entre les déférents temps d'exécution modèles de CNN.....	88
<b>Figure 67</b> : Confusion Matrix de modèle KNN .....	91
<b>Figure 68</b> : L'histogramme de la Comparaison entre les déférents modèles de CNN et les modèles de machine learning .....	92

## Liste des tableaux :

<b>Tableau 1:</b> Les étapes majeures du Deep Learning [6].....	6
<b>Tableau 2:</b> Critères de distinction entre tumeurs bénignes/ malignes.[38] .....	57
<b>Tableau 3:</b> Classification TNM.....	59
<b>Tableau 4:</b> Classification moléculaire des différents sous-types de cancer du sein. [40].....	60
<b>Tableau 5 :</b> Tableau de comparaison des résultats de modèle CNN .....	89
<b>Tableau 6 :</b> Résultat obtenue avec KNN .....	90
<b>Tableau 7:</b> Résultat obtenu avec NB .....	90
<b>Tableau 8:</b> Résultat obtenu avec DC .....	91

## Liste des Abréviations

<b>AI</b>	<b>Artificial Intelligence</b>
<b>DL</b>	<b>Deep Learning</b>
<b>ANN</b>	<b>Artificial Neural Network</b>
<b>CAD</b>	<b>Computer-Aided Detection And Diagnosis Cade Computer-Aided Detection</b>
<b>CNN</b>	<b>Convolutional Neural Network</b>
<b>KNN</b>	<b>K-Nearest Neighbors</b>
<b>ML</b>	<b>Machine Learning</b>
<b>LSTM</b>	<b>Long-Shor Term Memory</b>
<b>MLP</b>	<b>Multi-Layer Perceptron</b>
<b>ILSVRC</b>	<b>Imagenet Large Scale Visual Recognition Challenge</b>
<b>RELU</b>	<b>Rectified Linear Unit</b>
<b>RESNET</b>	<b>Residual Neural Network</b>
<b>RNN</b>	<b>Recurrent Neural Network</b>
<b>SVM</b>	<b>Support Vector Machines</b>
<b>TNM</b>	<b>Tumeur, Nodes, Métastase</b>
<b>VGG</b>	<b>Visual Geometry Group</b>
<b>GPU</b>	<b>Graphics Processing Unit</b>

## **Introduction Générale**

La mammographie est une technique d'imagerie médicale couramment utilisée pour le dépistage précoce du cancer du sein. Elle consiste en la prise de radiographies des tissus mammaires, permettant ainsi de détecter les lésions potentiellement cancéreuses. Cependant, l'interprétation des images mammographiques peut être difficile et nécessite souvent l'expertise d'un radiologue expérimenté.

L'étude comparative entre les réseaux de neurones convolutionnels (CNN) et l'algorithme K plus proches voisins (K-NN) en mammographie est un domaine de recherche important dans le domaine médical. Cette étude vise à évaluer et comparer l'efficacité de ces deux approches pour la détection et le diagnostic des anomalies mammaires à partir d'images de mammographie.

Les CNN sont des modèles d'apprentissage automatique spécialement conçus pour traiter les données d'images. Ils utilisent des couches de convolution pour extraire automatiquement les caractéristiques pertinentes des images et sont entraînés sur de vastes ensembles de données annotées afin d'apprendre à reconnaître différents motifs et structures présents dans les images. Les CNN ont montré des performances remarquables dans de nombreux domaines, y compris la vision par ordinateur et la reconnaissance d'images médicales.

D'autre part, l'algorithme K-NN est une méthode d'apprentissage supervisé qui se base sur la similarité des caractéristiques des échantillons. L'algorithme attribue une étiquette à un nouvel échantillon en fonction des étiquettes des k échantillons les plus proches dans l'espace des caractéristiques. En utilisant les caractéristiques extraites des images mammographiques, l'algorithme K-NN peut être appliqué pour classer les lésions comme bénignes ou malignes.

L'objectif de cette étude comparative est d'évaluer les performances des CNN et de l'algorithme K-NN dans la détection des anomalies mammaires à partir d'images mammographiques. Cela comprend l'évaluation des taux de détection, des taux de faux positifs, de la sensibilité et de la spécificité des deux approches. De plus, les aspects tels que la vitesse de traitement, la complexité computationnelle et les exigences en matière de données d'entraînement seront également pris en compte pour évaluer la faisabilité pratique des deux méthodes.

En résumé, cette étude comparative entre les CNN et l'algorithme K-NN en mammographie vise à fournir des informations précieuses sur l'efficacité et la pertinence de ces deux approches dans le contexte du dépistage précoce du cancer du sein. Les résultats de cette étude pourraient contribuer à améliorer les méthodes de diagnostic et à faciliter la prise de décision clinique en aidant les professionnels de la santé dans l'interprétation des images mammographiques.

Autre que l'introduction et la conclusion générale, notre mémoire est composé de 5 chapitres :

**Chapitre 1 : L'intelligence artificielle et l'apprentissage profond**

**Chapitre 2 : Généralités sur l'apprentissage automatique**

**Chapitre 3 : Traitement d'image**

**Chapitre 4 : Généralités sur le cancer du sein**

**Chapitre 5 : Implémentation et discussion des résultats**

# **Chapitre I : L'intelligence artificielle et l'apprentissage profond**



## **Introduction**

Tout au long de l'histoire, l'homme a cherché une invention qui peut imiter l'esprit humain dans sa vie quotidienne, un modèle de pensée. C'est pourquoi les scientifiques et les écrivains ont essayé de trouver une interprétation logique du concept d'intelligence artificielle, d'apprentissage profond et d'apprentissage automatique.

Au cours des dernières années, il y a eu des progrès significatifs. L'intelligence artificielle est devenue un sujet de recherche très actif dans plusieurs domaines et en particulier dans le domaine médical. L'apprentissage profond est un ensemble de technologies et un nouveau domaine de recherche en apprentissage machine qui repose entièrement sur des réseaux neuronaux synthétiques qui imitent le cerveau humain. L'objectif principal de l'initiative Machine Learning (ML) a été atteint.

### **I.1 L'intelligence artificielle (IA)**

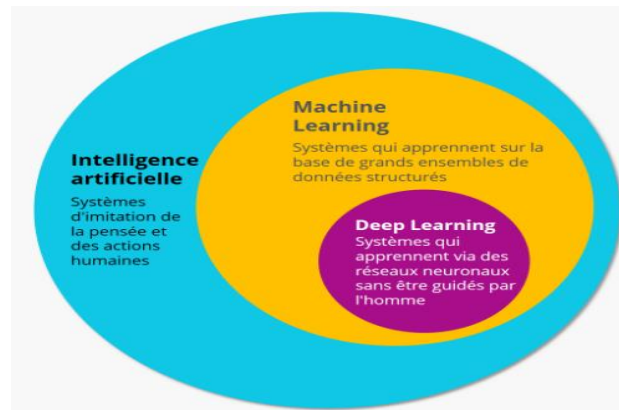
L'intelligence artificielle est une branche de l'informatique qui vise à développer des algorithmes et des systèmes informatiques qui peuvent effectuer des tâches qui nécessitent habituellement l'intelligence humaine, telles que la reconnaissance de la parole, la compréhension du langage naturel, la prise de décision et la résolution de problèmes complexes.

L'IA est fondée sur l'idée que les machines peuvent être programmées pour simuler l'intelligence humaine, et elle se base sur des disciplines telles que la théorie de l'information, la logique mathématique, la statistique et les réseaux de neurones pour développer ses algorithmes. [1]

L'IA est actuellement utilisée dans de nombreuses applications pratiques, telles que la reconnaissance vocale et visuelle, les systèmes de recommandation, les chatbots, les robots industriels, les systèmes de contrôle autonome, etc.

### I.1.1 Sous-domaines de l'Intelligence Artificielle

L'IA est un domaine très vaste et interdisciplinaire englobant de nombreux sous-domaines clés, y compris l'apprentissage automatique, l'apprentissage profond comme montre la figure 01 :



*Figure 1: La relation entre l'intelligence artificielle, le ML et le deep learning*

#### A. Apprentissage automatique (Machine Learning)

C'est la capacité d'un système à apprendre de manière autonome sans être explicitement programmé. Une spécialisation de l'intelligence artificielle qui consiste en un ensemble d'algorithmes (généralement appelés modèle) destinés à construire des applications intelligentes qui apprennent de l'expérience pour effectuer des prédictions intelligentes et s'améliorer au cours du temps sur la base d'un ensemble de données. La construction d'une application ML repose sur 4 étapes qui sont la sélection et la préparation d'un ensemble de données, le choix d'un algorithme à exécuter sur les données, l'entraînement de l'algorithme pour créer le modèle et enfin l'utilisation et l'amélioration du modèle [2]. Ce qui suit est une liste de certains des algorithmes ML couramment utilisés qui peuvent être appliqués à presque tout type de problème de données : Régression linéaire, Régression logistique, Arbre de décision, SVM, Naive Bayes, kNN, K-Means, Random Forest... etc. [3]


#### B. L'apprentissage profond (Deep Learning en anglais)

L'apprentissage profond (DL) est une sous-catégorie de l'apprentissage automatique qui se concentre sur l'utilisation de réseaux de neurones profonds pour modéliser des problèmes complexes. Les réseaux de neurones profonds sont des modèles formés par l'apprentissage supervisé, qui imitent le fonctionnement du cerveau humain en utilisant de nombreuses couches de nœuds interconnectés appelées "neurones".[4]

### a. Les avantages de DL et pourquoi nous l'avons choisi plutôt que ML

L'apprentissage profond est capable d'extraire, de traiter et d'apprendre des représentations de données dans leur forme originale, non modifiée. ML est très limitée dans l'apprentissage machine et pourrait ne pas être possible, il nécessite de sélectionner soigneusement les caractéristiques des données avec une grande compétence en ingénierie pour les représentations. L'avantage de DL sur ML est qu'il est capable de comprendre les caractéristiques des données brutes sans les extraire manuellement comme dans ML. [5]

Cela permet d'économiser du temps et des efforts, en particulier pour les données très volumineuses. En outre, les résultats obtenus par l'apprentissage profond sont meilleurs, plus précis et plus perfectionnés que ceux de l'apprentissage machine.



**Figure 2 :** La différence de performance entre le Deep Learning et la plupart des algorithmes de ML en fonction de la quantité de données.

– La différence de performance entre le Deep Learning et la plupart des algorithmes de ML en fonction de la quantité de données.

Une autre différence entre les algorithmes de ML traditionnelles et les algorithmes de Deep Learning c'est l'étape de l'extraction de caractéristiques. Dans les algorithmes de ML traditionnelles l'extraction de caractéristiques est faite manuellement, c'est une étape difficile et coûteuse en temps et requiert un spécialiste en la matière alors qu'en Deep Learning cette étape est exécutée automatiquement par l'algorithme.




Figure 3 : Le procède du ML classique comparé à celui du Deep Learning

## I.2 L'apprentissage profond

### I.2.1 Histoire du L'apprentissage profond

Année	Contributeur	Contribution
300AC	Aristotle	Introduction de l'associationnisme, début de l'histoire des humains qui essayent de comprendre le cerveau.
1873	Alexander Bain	Introduction du neural groupings comme les premiers modèles de réseaux de neurones.
1943	Meculloch and Pitts	Introduction du mcculloch-pitts (MCP)modèle considéré comme l'ancêtre des réseaux de neurones artificielles
1949	Donald Hebb	Considérer comme le père des réseaux de neurones, il introduit la règle d'apprentissage de Hebb qui servira de fondation pour les réseaux de neurones modernes.
1958	Frank Rosenbaltt	Introduction du premier perceptron
1974	Paul Werbos	Introduction de la retro propagation
1980	Teuvo Kohonen	Introduction des cartes auto organisatrices
1980	Kunihiko Fukushima	Introduction du Neocognitron, qui a inspiré les réseaux de neurones convolutif.
1982	John Hopfield	Introduction des réseaux de Hopfield
1985	Hilton and Sejnowski	Introduction des machines de Boltzmann
1986	Paul Smolensky	Introduction de Harmonium qui sera connu plus tard

		comme machines de Boltzmann restreint
1986	Michael I.Jordan	Définition et introduction des réseaux de neurones récurrents
1990	Yann Lecun	Introduction de LeNet et montra la capacité des réseaux de neurones profond
1997	Schuster and Paliwal	introduction des réseaux de neurones récurrents bidirectionnels
1997	Hochreiter and Schmidhuber	Introduction de LSTM, qui ont résolu le problème du vanishing gradient dans les réseaux de neurones récurrent
2006	Geoffrey Hinton	Introduction des deep belief Network
2009	Salakhutdinov and Hinton	Introduction de deep Boltzmann machines
2012	Alex Krizhevsky	Introduction de AlexNet qui remporta le challenge ImageNet

**Tableau 1:** Les étapes majeures du Deep Learning [6]

### **I.2.2 Définition**

Le deep learning est l'un des principaux éléments de la science des données. C'est un type de l'intelligence artificielle dérivé du machine learning (apprentissage automatique). Avec le deep learning, on parle d'algorithmes simulant le cerveau avec ou sans supervision humaine.

L'apprentissage profond est une discipline scientifique recherchant des méthodes de solution de problèmes à forte complexité logique ou algorithmique. Les modèles deep learning peuvent atteindre un niveau de précision exceptionnel, parfois supérieur aux performances humaines. [7]

### **I.2.3 Domaines d'application du deep learning**

Le deep learning est déjà utilisé dans un certain nombre de secteurs et est appelé à investir de nombreux aspects de notre vie quotidienne à l'avenir.

### **A. La reconnaissance faciale**

Les yeux, le nez, la bouche, tout autant de caractéristiques qu'un algorithme de Deep Learning va apprendre à détecter sur une photo. Il s'agit en premier lieu de donner un certain nombre d'images à l'algorithme, puis à force d'entraînement, l'algorithme va être en mesure de détecter un visage sur une image.

### **B. La détection d'objets**

Sur une image complexe où il y a plusieurs éléments, les algorithmes de détection d'objets vont être maintenant capables d'identifier et de localiser au pixel près un élément ou une personne. 800 millions d'images sont uploadées chaque jour sur Facebook : son algorithme Deep Learning est effectivement capable d'identifier telle ou telle personne sur une photo dès lors qu'elle est uploadée.

### **C. Traductions**

L'apprentissage profond est déjà à l'œuvre dans certains programmes de traduction automatique. Cette technologie permet en effet de reconnaître automatiquement, à partir de fichiers d'image, la langue d'un texte, ce qui n'était pas possible avec les anciennes applications d'apprentissage automatique, qui utilisaient des données structurées.

### **D. Conduite autonome**

Le développement des voitures sans conducteur semble appelé à participer à la sécurisation de la circulation routière à l'avenir. Mais la technologie nécessaire existe déjà. Il s'agit ici du fruit de la combinaison de différents algorithmes d'apprentissage profond : par exemple, un algorithme reconnaît les panneaux de signalisation tandis qu'un autre se spécialise dans la localisation des piétons.


### **E. Robots industriels**

Les robots dotés d'une IA avec deep learning pourraient être utilisés dans de nombreux secteurs industriels. Il suffirait à un système d'observer le comportement d'une personne pour faire fonctionner les machines, puis à optimiser de façon autonome le processus de production.

Les récentes avancées technologiques, et notamment en intelligence artificielle, ont impacté plusieurs aspects de notre quotidien. Les appareils intelligents nous facilitent la vie,

comme les dispositifs médicaux qui accélèrent le diagnostic de certaines maladies. Mais derrière ces progrès révolutionnaires se tiennent des processus souvent complexes. [7]

### I.2.4 Principe de fonctionnement de l'apprentissage profond



**Figure 4:** Schéma d'un neurone ouvert. [10]

L'apprentissage profond (Deep Learning en anglais) est un sous-ensemble de l'apprentissage automatique qui se concentre sur l'utilisation de réseaux de neurones artificiels pour résoudre des tâches complexes.

Le fonctionnement de base des réseaux de neurones implique la transmission d'entrée à travers plusieurs couches cachées de neurones pour générer une sortie. Chaque couche cachée comprend plusieurs neurones, qui sont connectés aux neurones de la couche d'entrée et de la couche de sortie. Les poids sont associés à ces connexions, et ils sont ajustés au cours de l'entraînement du modèle.

Lors de l'entraînement, les entrées sont transmises à travers le réseau, générant une sortie. La différence entre la sortie générée et la sortie souhaitée est utilisée pour ajuster les poids du réseau de manière à minimiser l'erreur. Cela est répété plusieurs fois en utilisant différents ensembles de données d'entraînement jusqu'à ce que la performance du modèle atteigne un niveau satisfaisant.

Lorsqu'un modèle est entraîné, il peut être utilisé pour faire des prédictions sur de nouvelles entrées en utilisant les poids ajustés. Les réseaux de neurones profonds sont appelés ainsi en raison de la profondeur de leurs couches cachées, qui peuvent comprendre des dizaines ou des centaines de couches. Cette profondeur permet aux réseaux de neurones profonds de capturer des caractéristiques complexes dans les données, ce qui les rend particulièrement utiles pour des tâches telles que la reconnaissance d'images, la génération de texte et la reconnaissance de la parole.

### **I.2.5 Les types d'apprentissage profond**

#### **A. Apprentissage supervisé**

L'apprentissage Supervisé est une méthode d'apprentissage automatique dans laquelle un modèle est entraîné à partir de données d'entrée et de sortie étiquetées. Le modèle utilise ces données pour apprendre à faire des prédictions précises sur de nouvelles données. Par exemple dans la classification d'images, des images étiquetées avec des étiquettes telles que "chien" ou "chat" sont utilisées pour entraîner un modèle à identifier les animaux dans de nouvelles images.

#### **B. Apprentissage non supervisé**

L'apprentissage Non Supervisé est une méthode d'apprentissage automatique où un algorithme est entraîné à trouver des motifs ou des structures dans un ensemble de données sans l'aide d'étiquettes ou de réponses prédéfinies. Les algorithmes d'apprentissage non supervisé sont souvent utilisés pour explorer et analyser des données, détecter des anomalies, regrouper des données similaires et réduire la dimensionnalité des données.

#### **C. Apprentissage semi-supervisé (hybride)**

L'apprentissage Semi-Supervisé hybride est une méthode d'apprentissage automatique qui combine à la fois des données étiquetées et non étiquetées pour améliorer les performances de la classification ou de la prédiction. Cette approche permet de tirer parti des données non étiquetées pour renforcer la qualité de la modélisation et de l'apprentissage, tout en limitant la nécessité d'étiqueter manuellement toutes les données d'entrée. Les modèles hybrides peuvent inclure des techniques telles que la classification par ensembles, la régularisation, la propagation de labels, etc. [7]



### **I.3 Réseaux de neurones**


#### **I.3.1 Qu'est-ce qu'un réseau de neurones ?**

Le concept de réseaux de neurones artificiels (Artificiel Neural Networks ANN) a été inspiré par les neurones biologiques. Dans un réseau de neurones biologiques plusieurs neurones travaillent ensemble, reçoivent des signaux d'entrée, traitent des informations et déclenchent un signal de sortie. [8]

#### **I.3.2 Neurone Biologique**

En général, le deep learning est considéré comme une technique plus avancée que le machine learning traditionnel, capable de traiter des données plus complexes et de donner des résultats plus précis dans des domaines tels que la reconnaissance d'images, la reconnaissance de la parole et le traitement du langage naturel. Cependant, il est important de noter que le deep learning peut également être plus difficile à configurer et à entraîner que d'autres techniques d'apprentissage automatique.[8]


Le neurone est une cellule spécialisée du système nerveux qui joue un rôle important dans la transmission de l'influx nerveux. Les neurones sont des cellules complexes qui comprennent une cellule corps, des dendrites qui reçoivent les entrées électriques et un axone qui transmet l'influx nerveux vers d'autres neurones ou vers les muscles ou les glandes. Les synapses, ou les jonctions entre les neurones, permettent à l'influx nerveux de passer d'un neurone à l'autre. Les neurones sont essentiels à la communication entre différentes parties du cerveau et du corps, ce qui est la base de la conscience, de la pensée, du mouvement et de toutes les fonctions du système nerveux.



**Figure 5:** Le neurone biologique [9]

### I.3.3 Neurone Artificiel

Un Neurone Artificiel est une forme de réseau de neurones, un type d'algorithme d'apprentissage automatique inspiré par le fonctionnement du cerveau humain. Les neurones artificiels imitent la structure des neurones biologiques en utilisant des algorithmes de calcul pour traiter et transmettre l'information. Les réseaux de neurones artificiels peuvent être formés pour effectuer diverses tâches complexes, telles que la reconnaissance d'images, la traduction automatique et la prédiction. Ils sont largement utilisés dans diverses applications telles que la reconnaissance vocale, la reconnaissance d'images, la traduction automatique, les jeux vidéo, la finance, la médecine et bien plus encore. Les neurones biologiques et les neurones artificiels sont des concepts similaires dans le sens où ils sont tous les deux des unités de traitement de l'information.



**Figure 6:** Neurone artificiel à entrées multiples [10]

### I.3.4 L'Analogie Entre le Neurone Biologique et le Neurone Artificiel

Les neurones biologiques et les neurones artificiels sont des concepts similaires dans le sens où ils sont tous les deux des unités de traitement de l'information.

Dans le système nerveux biologique, les neurones sont des cellules spécialisées qui transmettent des informations à travers des impulsions électriques appelées potentiels d'action. Chaque neurone a une ou plusieurs dendrites qui reçoivent des entrées électriques d'autres neurones, un corps cellulaire qui intègre ces entrées pour produire une réponse électrique, et un axone qui transmet cette réponse à d'autres neurones.

Les réseaux de neurones artificiels, en revanche, sont des modèles mathématiques qui imitent le comportement des réseaux de neurones biologiques. Ils sont formés de nœuds ou de neurones artificiels qui transmettent des informations à travers des connexions pondérées.

Chaque nœud reçoit des entrées de différents nœuds, les combine en fonction de poids associés à chaque connexion, puis transmet le résultat à d'autres nœuds.

En gros, le concept des neurones biologiques et des neurones artificiels est similaire, mais les détails de la façon dont ils travaillent peuvent être très différents. [8]

Les réseaux de neurones artificiels sont souvent conçus pour accomplir une tâche spécifique, tandis que les réseaux de neurones biologiques sont plus généraux et polyvalents, mais aussi plus complexes et difficiles à comprendre.

### **I.3.5 Des réseaux neuronaux aux réseaux neuronaux profonds**

Les réseaux neuronaux (RN) sont une forme de modèle d'apprentissage automatique qui se base sur les principes du traitement du signal dans le cerveau. Les réseaux neuronaux sont souvent utilisés pour la reconnaissance d'images, La classification de données et la prédiction de séquences.

Les réseaux neuronaux profonds (Deep Neural Networks **DNN**) sont une extension des réseaux neuronaux classiques, qui comportent plusieurs couches cachées de neurones. Les réseaux neuronaux profonds sont formés en ajoutant des couches supplémentaires à un réseau neuronal standard, ce qui les rend plus capables de capturer des structures complexes dans les données. Les DNN ont connu un succès remarquable dans de nombreux domaines, en particulier la reconnaissance de la parole, La reconnaissance d'images et la traduction automatique.


### **I.3.6 Les types des réseaux de neurones profonds**

Les architectures ANN sont trop nombreuses, nous n'en mentionnerons donc que quelques-unes qui sont liées à notre travail [10].

#### **A. Le perceptron multi-couches (MLP)**

Le perceptron multi-couches (MLP) est le modèle le plus utilisé dans les applications de réseau de neurones utilisant l'algorithme de l'entraînement à la rétropropagation. La définition de l'architecture dans les réseaux MLP est un point très pertinent, car un manque de connexions peut rendre le réseau incapable de résoudre le problème dû à l'insuffisance de paramètres réglables, tandis qu'un excès de connexions peut provoquer un surajustement des données de l'entraînement, surtout lorsque nous utilisons un nombre élevé de couches et de

neurones [10]. Un Perceptron multicouches est une variante du Modèle original de Perceptron proposé par Rosenblatt en 1950. Il comporte une ou plusieurs couches cachées entre sa couche d'entrée et sa couche de sortie, les neurones sont organisés en couches, les connexions sont toujours dirigées des couches gauches vers les couches droites, les neurones d'une même couche ne sont pas interconnectés, comme illustré dans la figure ci-dessous.



**Figure 7:** Les couches d'un perceptron multi-couches

Le nombre de neurones dans la couche d'entrée est égal au nombre de mesures pour le problème du modèle et le nombre de neurones dans la couche de sortie est égal au nombre de classes, le choix du nombre de couches et de neurones dans chaque couche et les connexions entre eux est appelé problème d'architecture. L'objectif principal est de le déterminer afin d'obtenir un réseau approprié, avec des paramètres suffisants et une bonne généralisation pour les tâches de la solution souhaitée.


## B. Réseau Feed Forward (FF)

Les réseaux feed-forward (FF) sont un type de réseau de neurones artificiels, qui sont conçus pour traiter des informations dans une direction uniquement, de l'entrée vers la sortie. Dans ces réseaux, les neurones sont organisés en couches, où chaque couche est connectée à la couche précédente et à la couche suivante. Les signaux d'entrée sont introduits dans la première couche, puis transmis couche par couche jusqu'à la couche de sortie. Le traitement de l'information dans un réseau FF se fait de manière séquentielle, sans rétroaction (feedback) entre les neurones d'une même couche. Cela signifie que la sortie de chaque couche dépend uniquement des entrées de la couche précédente et des poids de connexion entre les neurones. Les réseaux FF sont couramment utilisés dans de nombreuses applications telles que la reconnaissance d'images, la classification de textes, La prédiction de séries temporelles, la reconnaissance de la parole, etc. Ils sont

relativement faciles à entraîner et à utiliser, et ils ont montré des performances élevées dans de nombreuses tâches d'apprentissage automatique.

### C. Réseau neuronal convolutif (CNN)

Les Réseaux de Neurones Convolutionnels (ou convolutional neural networks, CNN) sont utilisés pour l'analyse d'images, où chaque couche applique des filtres de convolution pour extraire des caractéristiques d'image.



**Figure 8:** Structure générale d'un réseau de neurones convolutifs

Les CNN se composent de deux parties :

- **La partie cachée de l'extraction des caractéristiques :** Dans cette partie, le réseau effectuera plusieurs convolutions et des opérations de pooling jusqu'à ce que les features soient détectées et extraites.
- **La partie Classification :** Dans cette partie, les couches entièrement connectées (fully connected) jouent le rôle de classificateur sur ces caractéristiques extraites pour attribuer une probabilité pour l'objet sur l'image.

### D. Réseau neuronal récurrent (RNN)

Le Réseau Neuronale Récurrent est un réseau de neurones artificiels présentant des connexions récurrentes. Ils permettent de traiter des séquences temporelles (langage, vidéos, données numériques). Ils conservent la mémoire des données du passé pour prédire des séquences de données dans le futur proche. (By Patrick Hairy TM) Les RNN utilisent les sorties précédentes comme entrées supplémentaires et sont parfaitement adaptés au traitement de données séquentielles.




Figure 9: RNN exemple.

### E. Mémoire à long et court terme (LSTM)

Les réseaux LSTM (Long Short-Term Memory) sont un type de réseau de neurones récurrents (RNN) qui sont conçus pour traiter des séquences de données, comme des séquences de mots dans un texte ou des séquences de signaux dans une série chronologique. Les réseaux LSTM sont conçus pour résoudre le problème de la disparition du gradient qui se produit souvent avec les RNN traditionnels. Dans les RNN traditionnels, le gradient de l'erreur se propage de manière exponentielle en arrière dans le temps, ce qui peut rendre difficile l'apprentissage de relations à long terme. Les réseaux LSTM résolvent ce problème en introduisant une mémoire à long terme dans le réseau. Cette mémoire est contrôlée par des portes qui déterminent à quel moment les données doivent être stockées ou oubliées. Les portes sont des couches de neurones qui décident si l'information doit être conservée dans la mémoire à long terme ou si elle doit être oubliée. En utilisant des portes, les réseaux LSTM peuvent apprendre à conserver des informations importantes sur des périodes de temps plus longues, ce qui les rend particulièrement utiles pour le traitement de séquences de données. Les réseaux LSTM ont été utilisés pour une grande variété de tâches, notamment la traduction automatique, la reconnaissance vocale, la génération de texte, la prédiction de séries chronologiques et la reconnaissance d'entités nommées. [11]


#### I.3.7 Réseaux de Neurones Convolutifs (ConvNets/CNNs)

Un réseau neuronal convolutif (CNN) est un algorithme d'apprentissage profond qui peut prendre une image d'entrée, attribuer de l'importance (poids et biais apprenables) à divers aspects / objets de l'image et être capable de différencier l'un de l'autre. Ces dernières années, les CNNs sont devenus un élément central de toutes les méthodes de vision par ordinateur [11].

En 1980, Kunihiko Fukushima a proposé un réseau neuronal de reconnaissance d'image très basique dit le Néocognitron. Les ConvNets ont été introduits pour la première fois dans les années 1980 par Yann LeCun, chercheur postdoctoral en informatique. LeCun s'était appuyé sur le travail de Kunihiko Fukushima. La première version de l'architecture ConvNet, appelée LeNet améliorée par LeCuN et al., pouvait reconnaître les chiffres manuscrits. Les CNN ont trouvé un marché de niche dans les services bancaires, postaux et bancaires, où ils lisent les codes postaux sur les enveloppes et les chiffres sur les chèques.)

Un réseau de neurones convolutifs classique commence toujours par une couche de convolution. Cette couche détecte les caractéristiques de bas niveau telles que les arêtes et les courbes etc. Comme on pourrait l'imaginer, pour prédire si une image est un type d'objet, il est nécessaire que le réseau soit capable de reconnaître les caractéristiques de niveau supérieur telles que les mains, les pattes ou les oreilles. Lorsque nous traversons une autre couche de convolution, la sortie de la première couche de convolution devient l'entrée de la deuxième couche. Ainsi, chaque couche de l'entrée décrit en gros les emplacements de l'image d'origine à l'en- droit où certaines entités de bas niveau apparaissent. Désormais, lorsque nous appliquons un ensemble de filtres par-dessus (la deuxième couche de convolution), les activations générées.

Représentent des entités deni veau supérieur. Les types de ces caractéristiques peuvent être des demi-cercles (combinaison d'une courbe et d'un bord) ou des carrés (combinaison de plusieurs bords droits) etc. Au fur et à mesure que nous passons sur le réseau et que nous passons à travers plus de couches de convolution, nous obtenons des cartes d'activation qui représentent des fonctionnalités de plus en plus complexes [12]



**Figure 10:** L'erreur top -5 % des architectures gagnantes de la compétition ILSVRC

### **I.3.8 Le principe de Réseaux de neurones convolutifs**

Les réseaux de neurones convolutifs (convnets ou CNNs en anglais) sont une classe de réseaux de neurones artificiels particulièrement efficaces pour l'analyse et la classification d'images. Les convnets ont été introduits pour la première fois dans les années 1990, mais leur utilisation s'est généralisée avec l'augmentation de la puissance de calcul et la disponibilité de grandes quantités de données d'images. Les convnets sont basés sur l'utilisation de couches de convolution, qui appliquent des filtres à l'image d'entrée pour extraire des caractéristiques importantes telles que des bords, des formes et des textures. Les couches de convolution sont souvent suivies de couches de pooling, qui réduisent la taille de la sortie en prenant la moyenne ou le maximum des valeurs dans des zones prédéfinies. Les couches de convolution et de pooling sont souvent alternées plusieurs fois pour extraire des caractéristiques de plus en plus complexes à partir de l'image. Une fois que les caractéristiques ont été extraites, les couches de sortie du convnet effectuent une classification ou une régression en utilisant des couches de neurones entièrement connectées. Les convnets peuvent être entraînés à l'aide de techniques telles que la rétropropagation de l'erreur et l'optimisation par descente de gradient pour minimiser la fonction de perte. Les convnets sont largement utilisés dans de nombreux domaines, tels que la reconnaissance d'images, la détection d'objets, la segmentation d'images et la classification d'images médicales. Ils ont également été utilisés avec succès pour des tâches telles que la génération d'images et la traduction d'images.[12]

### **I.3.9 Types de couches dans le réseau neuronal convolutif**

Une architecture CNN est formée par un empilement de couches de traitement indépendantes [13] :

- **La couche de convolution (CONV)** qui traite les données d'un champ récepteur.
- **La couche de pooling (POOL)**, qui permet de compresser l'information en réduisant la taille de l'image intermédiaire (souvent par sous-échantillonnage).
- **La couche de correction (ReLU)**, souvent appelée par abus 'ReLU' en référence à la fonction d'activation (Unité de rectification linéaire).
- **La couche "entièrement connectée" (FC)**, qui est une couche de type perceptron.
- **La couche de perte (LOSS)**



## **A. Couche convolutive (Convolutional layer CONV)**

La couche de convolution a des noyaux (filtres) et chaque noyau a une largeur, une profondeur et une hauteur. Cette couche produit les cartes de caractéristiques à la suite du calcul du produit scalaire entre les noyaux et les régions locales de l'image.

La couche de convolution (convolutional layer en anglais, souvent abrégée CONV) est l'un des éléments clés d'un réseau de neurones convolutionnel (CNN). Cette couche permet d'extraire des caractéristiques à partir des données d'entrée en appliquant des filtres de convolution.

Plus précisément, une couche de convolution prend en entrée un tenseur représentant les données (par exemple une image) et un ensemble de filtres de convolution (aussi appelés noyaux de convolution). Chaque filtre est une petite matrice de nombres qui est glissée sur l'image d'entrée pour effectuer une opération de convolution.

L'opération de convolution consiste à superposer le filtre sur chaque petite région de l'image d'entrée et à effectuer une multiplication élément par élément entre les valeurs du filtre et les valeurs de l'image dans cette région. Les résultats de ces multiplications sont ensuite sommés pour produire une seule valeur qui représente l'activation du filtre pour cette région. Cette opération est répétée pour toutes les régions de l'image pour produire une carte d'activation.

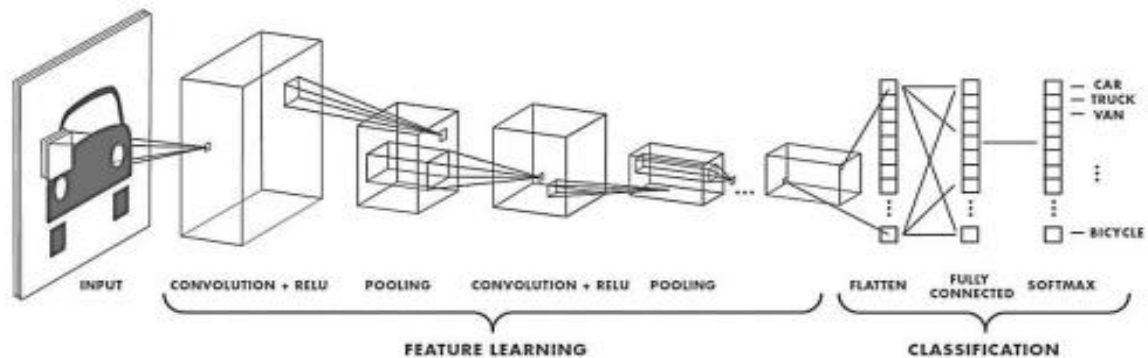
En appliquant plusieurs filtres à l'image d'entrée, la couche de convolution est capable d'extraire différentes caractéristiques de l'image, telles que des bords, des coins, des textures, des formes, etc. Les cartes d'activation résultantes sont ensuite passées à la couche suivante du réseau pour être transformées davantage. Trois hyper paramètres permettent de dimensionner le volume de la couche de convolution (aussi appelé volume de sortie) : la profondeur, le pas et la marge. [13]

**1. Profondeur de la couche :** nombre de noyaux de convolution (ou nombre de neurones associés à un même champ récepteur).

**2. 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.

**3. La marge (à 0) ou 'zero padding' :** parfois, il est commode de mettre des zéros à la frontière du volume d'entrée. La taille de ce 'zero-padding' est le troisième hyperparamètre.

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. [14]



**Figure 11:** Exemple de réseau composé de nombreuses couches à convolution. Des filtres sont appliqués à chaque image utilisée pour l'apprentissage à différentes résolutions, et la sortie de chaque image convoluée est utilisée comme entrée de la couche suivante. [16]


Dans la terminologie du réseau convolutif, le premier argument de la convolution est souvent appelé l'entrée (**input**) et le second argument comme noyau (**kernel**). La sortie est parfois appelée la carte des caractéristiques (**feature map**).

## B. Couche d'unité linéaire rectifiée (Rectified Linear Unit layer ReLU)

La couche d'unité linéaire rectifiée (en anglais rectified linear unit layer) (ReLU) est une fonction d'activation qui est utilisée sur tous les éléments du volume permet d'éliminer toutes les valeurs négatives et conserver les valeurs positives. Elle a pour but d'introduire des complexités non-linéaires au réseau.

## C. Couche de Pooling

Le pooling est une forme de sous-échantillonnage de l'image Une couche de Pooling (regroupement) prend chaque sortie des cartes de caractéristiques résultantes de la couche de convolution et la sous-échantillonne. Les techniques de regroupement les plus courantes sont MaxPooling et Average Pooling. La couche de pooling fonctionne indépendamment sur chaque tranche de profondeur de l'entrée et la redimensionne uniquement au niveau de la surface.



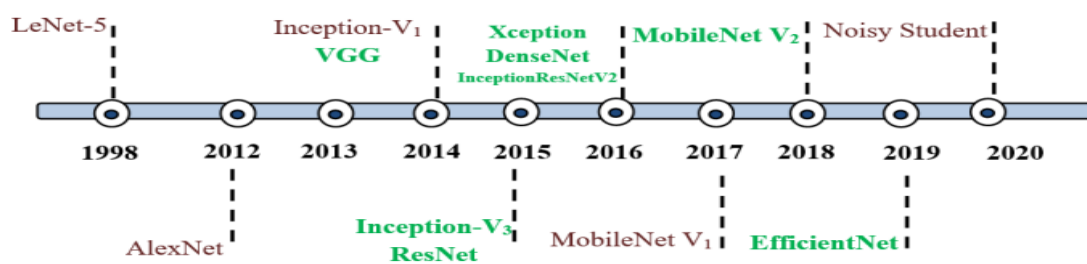
*Figure 12: Exemple de fonctionnement de Max pooling et Average pooling*

## I.4 Etat de l'art

### I.4.1 Les Architectures de CNN

De nos jours, les CNN sont considérés comme les algorithmes les plus largement utilisés parmi les inspirés des techniques d'Intelligence Artificielle (IA). L'histoire de CNN commence par le neurobiologique expériences menées par Hubel et Wiesel (1959, 1962) [15]. Leur travail a fourni une plate-forme pour de nombreux modèles cognitifs, et CNN a remplacé presque tous ceux-ci. Au fil des décennies, différents efforts ont été menés pour améliorer les performances des CNN.

Il existe de nombreuses architectures CNN réputées. Les architectures CNN les plus populaires sont données dans la figure 13.



*Figure 13: Histoire évolutive des CNNs montrant les innovations architecturales*

#### A. LeNet-5

Les premières applications réussies des réseaux convolutifs ont été développées par **Yann LeCun** dans les années 1990. Parmi ceux-ci, le plus connu est l'architecture LeNet utilisée pour lire les codes postaux, les chiffres, etc. [16]

### a. La structure LeNet-5

LeNet-5 est une structure CNN d'apprentissage basée sur le gradient et d'abord appliquée avec succès dans la reconnaissance numérique de caractères manuscrite. Le diagramme de structure typique de LeNet-5 est illustré à FIG 08. Sa couche d'entrée est une image numérique manuscrite de 0 ~ 9 avec une taille de  $32 \times 32$ , et sa couche de sortie a 10 nœuds correspondant à des nombres de 0 ~ 9. En plus des couches d'entrée et de sortie, LeNet-5 comprend généralement six couches, qui sont trois couches convolutionnelles, deux couches de pooling et une couche entièrement connectée. La taille du noyau convolutif est définie sur  $5 \times 5$  dans la couche convolutive et le cœur dans la couche de mise en commun est définie sur  $2 \times 2$ . La couche de connexion complète réduit le nombre de neurones de 120 à 84 pour réduire l'entraînement des paramètres. [16].




Figure 14: La structure LeNet-5 proposée par Yann LeCun [16]

### B. AlexNet

Le premier travail qui a popularisé les réseaux convolutifs dans la vision par ordinateur était AlexNet, développé par **Alex Krizhevsky**, Ilya Sutskever et Geoff Hinton. AlexNet a été soumis au défi ImageNet ILSVRC [16] en 2012 et a nettement surpassé ses concurrents. Le réseau avait une architecture très similaire à LeNet, mais était plus profond, plus grand et comportait des couches convolutives empilées les unes sur les autres (auparavant, il était commun de ne disposer que d'une seule couche convolutifs toujours immédiatement suivie d'une couche de pooling)

#### a. Structure du réseau AlexNet

AlexNet a été proposé par Krizhevsky et Al. [16] et a remporté le championnat dans la compétition 2012 Image Net ce qui plus que doublé la reconnaissance de précision de

ImageNet. Le modèle se compose d'une structure de 8 couches et a sa possession exceptionnelle Advan-in image classification La structure spécifique d'AlexNet

Le format d'entrée des données sources est de 227 227 3 pixs, par lequel 227 pix représente la largeur et la hauteur de l'entrée Im-âge 3 Représente les données sources est un mode RVB à trois canaux ainsi Prend en charge les photos en couleur dans les formats couramment utilisés donc il n'y a pas besoin de formats supplémentaires pour les sources de données en langue source recueillies Recadré.

Le processus de calcul des deux premières couches est convolu- (Conv), ReLu, mutualisation maximale (max-pooling) et normaliza-(normal). Le résultat de sortie de la deuxième couche est 256 Fonction de carte pour opération de convolution dans laquelle la taille du noyau est 5, la foulée est 1, et les autres paramètres sont les mêmes que première couche. Les troisième et quatrième couches seulement effectué convolution et ReLu Operations. La cinquième couche est similaire à la première couche ex-CEPT qu'il n'a pas été Normalisé. Convertir le résultat de la cinquième couche dans un vecteur long et l'a entré dans un réseau neuronal traditionnel travail En utilisant une structure complètement connectée à trois couches. Les cœurs des deux premiers Calques complètement connectés sont respectivement 4.096. La dernière couche Génère 1000 nœuds et l'étiquette de valeur peut être obtenue en utilisant la régression fonctionnelle Softmax.[19]





Figure 15: Exemple de CNN appelé AlexNet.

### C. VGG-19

Le réseau VGG est le nom commercial d'un modèle CNN pré-entraîné proposé par **Simonyan** et **Zisserman** à l'Université d'Oxford, au Royaume-Uni, début 2014. VGG (Visual Geometry Group) est formé sur le jeu de données ILSVRC ImageNet de 1,3 million d'images dans 1000 catégories, avec 100 000 images pour la formation et 50 000 images pour la validation. VGG-19, une variante de l'architecture VGG avec 19

couches profondément connectées, atteint systématiquement de meilleures performances que les autres modèles leaders. Le modèle se compose de couches convolutives et entièrement connectées hautement connectées pour une meilleur extraction des caractéristiques, et utilise la mise en commun maximale (au lieu de la mise en commun moyenne) pour sous-échantillonner la classification avant d'utiliser la fonction d'activation SoftMax.



*Figure 16: Architecture du modèle VGG-19.[18]*

## D. GoogleNet

Le vainqueur de ILSVRC challenge 2014 était un réseau convolutif de Szegedy et al. De Google. Sa principale contribution a été le développement d'un module inception qui a considérablement réduit le nombre de paramètres dans le réseau (4M, par rapport à AlexNet avec 60M). En outre, ce module utilise le global AVG pooling au lieu du PMC à la fin du réseau, ce qui élimine une grande quantité de paramètres. Il existe également plusieurs versions de GoogLeNet, parmi elles, Inception-v4 proposée par une **équipe de chercheurs** de l'Université Cornell, composée de Gao Huang, Zhuang Liu, Laurens van der Maaten et Kilian Q. [20]

### a. Applications de GoogLeNet

Le gagnant de l'ILSVRC14, GoogLeNet, s'est avéré performant sur une variété Pouyan et coll.20 ont proposé une méthode pour effectuer la détection d'obstacles qui consiste en un NDN non supervisé sur GoogLeNet pour extraire les caractéristiques globales de l'image et un supervisé pour extraire caractéristiques locales de l'image (bloc). De plus, Tian et al.24 utilisent l'apprentissage par transfert méthode pour aider à la formation de GoogLeNet pour la stéganalyse.

Afin de s'appliquer au HCCR hors ligne, Zhong et al.29 ont conçu une version simplifiée de GoogLeNet nommée HCCR-GoogLeNet. Il n'a que 19 couches et moins

paramètres que le modèle GoogLeNet original. HCCR-GoogLeNet atteint de nouvelle précision de reconnaissance de pointe.

### E. ResNet

ResNet est proposé par une équipe de recherche de Microsoft et Kaiming. Ils ont montré que l'ajout des connections entre les couches (les liens résiduels) peut représenter des chemins simples pour la propagation de gradient, ce qui rend la mise à jour des poids plus efficaces. Il a fallu deux à trois semaines pour l'entraîner sur une machine à 8 GPU. Ce modèle arrive à une erreur Top-5 de 3.57 %, qui dépasse l'erreur humaine qui est estimée à 5%.




Figure 17: réseau convolutifs le Resnet

### F. FaceNet

FaceNet est un système de reconnaissance faciale développé en 2015 par Florian Schroff et al. chez Google.

### G. DenseNet

proposé a été faite par une **équipe de chercheurs de Google**, notamment Christian Szegedy, Wei Liu, Yangqing Jia, Pierre Sermanet, Scott Reed, Dragomir Anguelov, Dumitru Erhan, Vincent Vanhoucke, and Andrew Rabinovich Considérons une seule image  $x_0$  qui est passée par un réseau conventionnel. Le réseau comprend des couches  $L$ , chaque dont met en œuvre une transformation non linéaire  $H(X_0)$ , où  $l$  indexe la couche.  $H^l(X_0)$  peut être une fonction composite d'opérations telles

que la normalisation par lots (BN), unités linéaires rectifiées (ReLU), Pooling ou Convolution (Conv).th layer as  $x^l$ .

## **H. U-NET : le réseau de neurones de Computer Vision**

Le réseau U-net est adapté à tous les types de problèmes de segmentation. Il permet la segmentation de grandes images.

Dans ce contexte, cet article présente en détail application d'un réseau U-net en six images les systèmes et l'analyse d'images médicales, y compris tomographie (CT), imagerie par résonance magnétique (IRM), échographie, radiographie, tomographie par cohérence optique (TCO), et la tomographie par émission de positrons (TEP). Désormais, les réseaux de neurones convolutifs de Deep Learning sont très utilisés. Ils permettent de s'attaquer à des problèmes plus complexes grâce à la segmentation d'image. U-Net est séparée en 3 parties :

1. La voie de contraction / sous-échantillonnage
2. goulot d'étranglement
3. La voie d'extension / suréchantillonnage [20]

### **a. L'architecture de U-NET :**

Proposé a été faite par les chercheurs Olaf Ronneberger, Philipp Fischer et Thomas Brox. U-NET est composée de deux "chemins". Le premier est le chemin de contraction, aussi appelé encodeur. Il est utilisé pour capturer le contexte d'une image.

Il s'agit en fait d'un **assemblage de couches de convolution** et de couches de "max pooling" permettant de créer une carte de caractéristiques d'une image et de réduire sa taille pour diminuer le nombre de paramètres du réseau.

Le second chemin est celui de l'expansion symétrique, **aussi appelé décodeur**. Il permet aussi une localisation précise grâce à la convolution transposée.

la figure chaque boîte bleue correspond à une carte de caractéristiques multi-canaux. Le nombre de canaux est indiqué en haut de la boîte, et la taille de la carte est indiquée dans le coin inférieur gauche de la boîte. Les cases blanches représentent des cartes de caractéristiques copiées. Les flèches indiquent les différentes opérations (affichées également dans la légende). La partie gauche du U est l'encodeur, et la partie droite est le décodeur (nous allons détailler dans la section suivante)






Figure 18: L'architecture de Réseau entièrement convolutionnel U-Net pour une image  $32 \times$

32

U-Net est l'une des architectures les plus populaires pour la segmentation des images médicales. Il se compose de deux chemins : un chemin de contraction et un chemin d'expansion.

### b. Les avantages de U-NET

U-Net est un modèle de réseau de neurones convolutionnel qui a été conçu pour les tâches de segmentation d'images. Il présente les avantages suivants :

-Une **architecture autoencoder classique** réduit la taille des informations entrées, puis les couches suivantes. Le décodage commence ensuite, la représentation de caractéristiques linéaire est apprise et la taille augmente progressivement. À la fin de cette architecture, la taille de sortie est égale à la taille d'entrée. [20]

- U-NET permet de remédier à ces problèmes, puisqu'il s'avère **efficace même avec un ensemble de données limité**. Il offre aussi une précision supérieure aux modèles conventionnels.

-**Architecture de codage-décodage** : L'architecture en forme de "U" de U-Net permet une transmission efficace des informations à travers les couches, en passant par les couches de codage pour collecter les informations à un niveau plus élevé d'abstraction, puis en les transmettant à travers les couches de décodage pour une segmentation détaillée.

-**Rétention de la résolution spatiale** : U-Net a été conçu pour conserver la résolution spatiale des entrées d'images en utilisant des connexions concaténées entre les couches de

codage et de décodage. Cela permet une segmentation plus précise en préservant les détails de l'image d'entrée.

**-Apprentissage en profondeur :** U-Net est un modèle à profondeur totale, ce qui permet une meilleure reconnaissance des features complexes dans les images.

**-Flexibilité :** U-Net est flexible en termes de taille et de nombre de couches, ce qui en fait un choix populaire pour une variété de tâches de segmentation d'images.

**-Performances élevées :** U-Net a montré des performances élevées dans plusieurs tâches de segmentation d'images, en particulier pour les données à faible échantillonnage et les images médicales.

### **c. Comment apprendre à utiliser U-NET ?**

U-Net est un modèle de réseau de neurones convolutifs utilisé principalement pour la segmentation d'image. Pour apprendre à utiliser U-Net, voici quelques étapes à suivre :

- **Apprendre les bases des réseaux de neurones convolutifs**

avant d'apprendre U-Net, il est important de connaître les bases des réseaux de neurones convolutifs, y compris les convolutions, les couches de pooling, les fonctions d'activation, etc. [20]

### **d. Comprendre le fonctionnement de U-Net**

U-Net est un réseau de neurones convolutifs qui utilise une architecture d'encodeur-décodeur. Il comprend deux parties principales : l'encodeur qui extrait les caractéristiques de l'image et le décodeur qui restaure l'image segmentée. Obtenir des données d'entraînement :

- **Pour entraîner un modèle U-Net,** vous devez disposer d'un ensemble de données d'images avec des annotations de segmentation. Ces annotations peuvent être manuellement créées ou obtenues à partir de sources telles que des bases de données d'images annotées.

- **Prétraiter les données :** Les images doivent être prétraitées pour être normalisées et redimensionnées. Les masques de segmentation doivent être binarisés et redimensionnés pour correspondre aux dimensions de l'image.

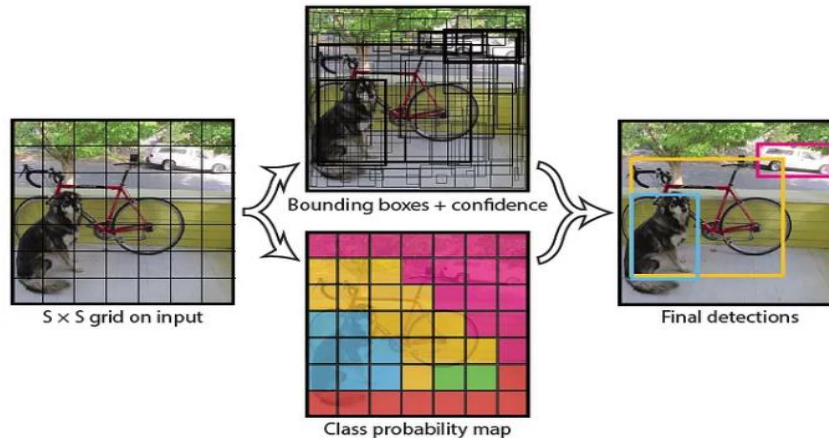
- **Entraîner le modèle :** Vous pouvez entraîner le modèle U-Net à l'aide de bibliothèques de deep learning telles que TensorFlow ou PyTorch. Il est important de régler les hyperparamètres correctement pour obtenir les meilleurs résultats.
- **Évaluer le modèle :** Après l'entraînement, évaluez le modèle sur un ensemble de données de test pour évaluer sa précision et sa performance. Si nécessaire, ajustez les paramètres du modèle et ré-entraînez-le.

Enfin, la pratique et l'expérience jouent un rôle important dans l'apprentissage de l'utilisation de U-Net. Il est recommandé de suivre des tutoriels et de travailler sur des projets d'exemple pour acquérir de l'expérience dans l'utilisation de U-Net. [20]

## **I. Modèle YOLO**

YOLO (« You Only Look Once ») est un algorithme efficace de reconnaissance d'objets en temps réel. YOLO est implanté à Darknet qui est un réseau neuronal open-source cadre. YOLOv3 utilise une variante de Darknet. Le modèle de Darknet se compose d'un réseau de 53 couches qui est formé sur l'ensemble de données Imagenet et 53 autres couches sont empilés dessus, donnant une architecture entièrement convolutionnelle de 106 couches pour YOLOv3. La figure illustre le modèle YOLO.

Le modèle YOLOv3 : est mis en œuvre par transfert d'apprentissage (en utilisant des poids préformés). Il y a 80 classes d'objets dans le modèle. Lorsqu'une image d'entrée est donnée, elle passe par une série d'étapes. Premièrement, le nombre des boîtes d'ancrage et leurs dimensions sont fixes, l'image est passée dans le modèle sous forme de grille. Le centre des objets est assigné à certains carrés de la grille. Intersection au-dessus de l'Union est utilisée pour déterminer quelle ancre convient le mieux à l'objet. Il y a plusieurs boîtes assignées pour un seul objet résoudre cette suppression non fiscale est appliquée qui ne ferait que sélectionner les cases avec la probabilité maximale et jeter d'autres boîtes avec l'intersection élevée sur Union (IoU) par rapport à la case sélectionnée. Le modèle produit une image avec des encadrés autour des objets détectés avec leurs correspondants étiquettes. Les coordonnées de ces boîtes de délimitation peuvent être utilisées pour recadrer les objets de l'image. Les segments de l'image qui ont leur étiquette correspondante en tant que « personne » sont alimentés au modèle de création un par un pour une classification ultérieure et les autres objets sont produits avec leurs étiquettes.[22]



*Figure 19: YOLO model [22]*

### I.4.2 Avantages de CNNs

Un avantage majeur des réseaux convolutifs est l'utilisation d'un poids unique associé aux signaux entrant dans tous les neurones d'un même noyau de convolution. Cette méthode réduit l'empreinte mémoire, améliore les performances et permet une invariance du traitement par translation. C'est le principal avantage du CNN par rapport au MLP, qui lui considère chaque neurone indépendant et donc affecte un poids différent à chaque signal entrant. Lorsque le volume d'entrée varie dans le temps (vidéo ou son), il devient intéressant de rajouter un paramètre de temporisation (delay) dans le paramétrage des neurones. On parlera dans ce cas de réseau neuronal à retard temporel (TDNN). Comparés à d'autres algorithmes de classification de l'image, les réseaux de neurones convolutifs utilisent relativement peu de pré-traitement. Cela signifie que le réseau est responsable de faire évoluer tout seul ses propres filtres (apprentissage sans supervision), ce qui n'est pas le cas d'autres algorithmes plus traditionnels. L'absence de paramétrage initial et d'intervention humaine est un atout majeur des CNN.[23]

### I.4.3 Les inconvénients des réseaux de neurones à convolution (CNN) :

- Besoin de données étiquetées : Les CNN nécessitent un grand nombre de données étiquetées pour un entraînement efficace. L'annotation manuelle des données peut être coûteuse et fastidieuse.
- Sensibilité à la taille et à la qualité des données : Les CNN peuvent être sensibles à la taille et à la qualité des données d'entrée. Des images de résolution trop basse ou floues peuvent entraîner une baisse des performances.


- Représentations non interprétables : Les CNN sont souvent considérés comme des "boîtes noires", car il peut être difficile de comprendre comment les caractéristiques sont extraites des données en entrée.
- Besoin de puissance de calcul : Les CNN sont des modèles complexes qui nécessitent une puissance de calcul significative, en particulier lorsqu'ils sont appliqués à de grandes images ou à des volumes de données massifs.[23]

## I.5 Fonction d'activation

Une fois que le neurone a effectué le produit entre son entrée et son poids, il applique également la non-linéarité de ce résultat. Cette fonction non linéaire est appelée fonction d'activation. Les fonctions d'activation sont une partie importante des réseaux de neurones. Qu'est-ce que c'est ça La fonction de la décision est de savoir si le neurone est activé ou non. Il calcule la somme pondérée des entrées et ajoute du biais. Il s'agit d'une transformation non linéaire des valeurs d'entrée. Après transformation, cette sortie est envoyée à la couche suivante. Non linéaire comme ça C'est très important dans le réseau neuronal, il n'y a pas de fonction d'activation, réseau neuronal devient simplement un modèle linéaire. Il existe plusieurs types de ces fonctions, parmi lesquelles nous découvrons:

### I.5.1 Fonction sigmoïde

Cette fonction est l'une des plus couramment utilisées. Il est compris entre 0 et 1, et il peut être interprété de manière stochastique comme la probabilité d'activation d'un neurone, qui est souvent appelée fonction logistique ou sigmoïde logistique




*Figure 20:* histogramme de fonction sigmoïde

### I.5.2 Fonction de Relu

La fonction ReLu est probablement la plus proche des homologues biologiques. Ces fonctions sont récemment devenues le choix pour de nombreuses tâches (en particulier

en informatique vision), cette fonction renvoie 0 si l'entrée  $z$  est inférieure à 0, et  $z$  elle-même si elle est Supérieure à 0.



**Figure 21:** histogramme de fonction Relu

### **Conclusion**

Dans ce chapitre on a présenté les notions importantes qui sont en relation avec l'apprentissage profond (définition, Architectures....etc). Aussi qu'une vision générale sur l'apprentissage profond, et nous avons présenté quelques modèles tel que AlexNet, DenseNet, etc. vu que notre travail repose sur les CNNs.

*Chapitre II : Généralités sur  
l'apprentissage automatique*

### ***Introduction***

L'apprentissage automatique est un sous-domaine de l'informatique concerné par la construction d'algorithmes utiles qui s'appuient sur un ensemble d'exemples d'un phénomène particulier. Ces exemples peuvent être naturels, artificiels ou produits par un autre algorithme. L'apprentissage automatique peut également être défini comme la résolution de problèmes réels en collectant ensemble de données et en construisant des algorithmes pour les modèles statistiques basés sur cet ensemble de données. Ce modèle statistique devrait être utilisé d'une manière ou d'une autre pour résoudre de vrais problèmes. Une définition plus générale : L'apprentissage automatique est un domaine d'étude de la capacité d'un ordinateur à apprendre sans être explicitement programmé.

### **II.1 Définition**

L'apprentissage automatique comporte généralement deux phases. La première consiste à estimer le modèle à partir de données (appelées observations), disponibles et en nombre limité, lors de la phase de conception du système. L'estimation du modèle comprend la résolution de tâches pratiques telles que la traduction de la parole, l'estimation des densités de probabilité, la participation à la conduite d'une voiture autonome. Cette phase dite « d'apprentissage » ou « d'entraînement » intervient généralement avant l'utilisation effective du modèle. La deuxième phase correspond au lancement de la production : le modèle est déterminé, après quoi de nouvelles données peuvent être mises pour obtenir des résultats correspondant aux tâches requises. En pratique, certains systèmes peuvent poursuivre l'apprentissage une fois en production, à condition d'avoir un moyen d'obtenir un retour sur la qualité des résultats produits. [24]



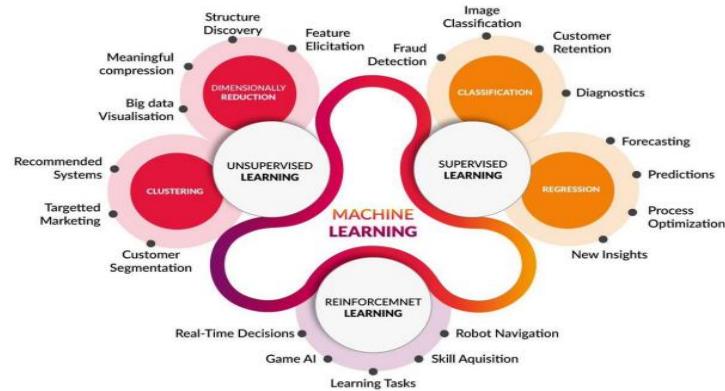


Figure 22: Quelques types de problèmes d'apprentissage automatique.

## II.2 les algorithmes de l'apprentissage automatique utilisés

### II.2.1 Apprentissage supervisé

Dans l'apprentissage supervisé, les données de formation que l'on fournit à l'algorithme comprennent les solutions, appelées étiquettes (ou labels en anglais).

- K plus proches voisins
- Machines à vecteurs de support (SVM)
- Naïve\_Bayes

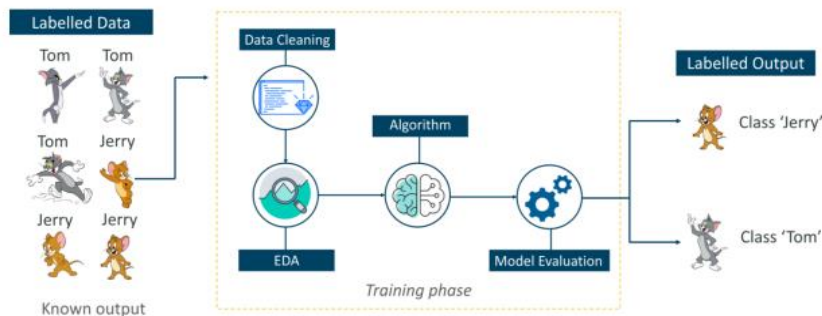


Figure 23: Apprentissage supervisé.

### II.2.2 Apprentissage non supervisé

dans l'apprentissage non supervisé, les données d'apprentissage ne sont pas étiquetées. Le système tente d'apprendre sans professeur.

### A. Knearest neighbors (KNN)

K nearest neighbors (KNN) ou K plus proche voisins en français est l'un des méthodes d'apprentissage supervisé le plus simple, utilisé pour résoudre des problèmes de classification et de la régression. son fonctionnement est de classer les nouveaux points de données en fonction de la similarité aux points de données voisins.

- KNN est un algorithme qui ne fait aucune hypothèse sur la structure et la distribution des données, ce qui signifie qu'il s'agit d'un algorithme non paramétrique.

- Il est également connu sous le nom d'algorithme d'apprentissage paresseux car il n'apprend médiatement à partir de l'ensemble d'apprentissage, mais stocke à la place l'ensemble de données et effectue des opérations sur celui-ci lors de la classification.

- KNN classe ou prédit sur la base d'un nombre fixe (K) de points de données les plus proches du point d'entrée. Cela signifie que pour une valeur de K choisie, le point d'entrée sera classé ou devra appartenir à la même classe que celui qui plus de points K voisins. [24]

#### Exemple




Figure 24: Exemple simple sur KNN

#### a. Algorithme de construction de KNN

L'algorithme des K plus proches voisins ou K-nearest neighbors (kNN) est un algorithme de Machine Learning qui appartient à la classe des algorithmes d'apprentissage supervisé simple et facile à mettre en œuvre qui peut être utilisé pour résoudre les problèmes de classification et de régression, Les algorithmes KNN utilisent des données et classifient les nouveaux points de données en fonction de mesures de similarité (fonction de distance). Le classement se fait à la majorité de ses voisins. Les données sont affectées à la classe qui a les voisins les plus proche.

La méthode KNN est donc une méthode à base de voisinage, non-paramétrique Ceci signifiant que l'algorithme permet de faire une classification sans faire d'hypothèse qui relie la variable dépendante aux variables indépendantes.[25]

**b. L'algorithme KNN**

1. Sélectionnez le nombre K des voisins.
2. Pour chaque exemple de l'ensemble de données :

2.1. Calculez la distance entre l'exemple de requête et l'exemple actuel à partir des données.

2.2. Ajouter la distance et l'index de l'exemple à une collection ordonnée.

3. Trier cette collection de distances et d'indices du plus petit au plus grand (par ordre croissant) ordonnée par les distances.

4. Choisi les k premiers entrée de collections.

5. Attribuer l'exemple de requête à la classe ou laquelle le nombre de k voisins est maximal (classe le plus fréquent).

**• Algorithme des k plus proches voisins pondérés et application en diagnostic Eve Mathieu-Dupas**

Il existe plusieurs fonctions de calcul de distance, notamment, la distance euclidienne, la distance de Manhattan, la distance de Hamming etc. ...

On choisit la fonction de distance en fonction des types de données qu'on manipule

**1.La distance euclidienne :** Il s'agit de la mesure de distance la plus couramment utilisée, elle est une bonne mesure à utiliser quand les données (input variables) ne sont pas du même type (exemple : âge, sexe, longueur, poids etc...), Il mesure une ligne droite entre le point de requête et l'autre point mesuré.

$$D(x,y) = \sqrt{\sum_{j=1}^n (x_j - y_j)^2}$$

**2.Distance Manhattan :** C'est une mesure de distance populaire, qui mesure la valeur absolue entre deux points, utilisé pour les données quantitatives (exemple : poids, salaires, taille, montant de panier électronique etc...).

$$D(x,y)=\sum_{i=1}^k | X_i - Y_j |$$

**c. Avantage de KNN**

1. Simple à implémenter
2. Gérer naturellement les cas multi classes
3. Peut être utilisé pour la classification et la régression

**d. Inconvénients de KNN**

1. le choix de la valeur de k (le nombre de voisins le plus proche)
2. Le cout de calcul est élevé (pour chaque instance de l'ensemble de données on a besoin de calculer la distance)
2. Stockage de données
3. Sensible aux fonctionnalités non pertinentes

**B. Random Forest (forêts aléatoires)**

Random Forest ou forêts aléatoires est un algorithme d'apprentissage supervisé très populaire Il est également utilisé pour les problèmes de régression ou de classification. Basé sur un ensemble des algorithmes d'apprentissage, qui est un processus de combinaison de plusieurs algorithmes pour résoudre un problème complexe et améliorer les performances du modèle. C'est un algorithme qui créer de nombreux arbres de décision (c'est la raison pour laquelle il est appelé une forêt) sur divers sous-ensembles de l'ensemble de données. Elle prend la prédiction de chaque arbre et sur la base des votes majoritaires des prédictions, et elle prédit le résultat final et La figure suivant explique le fonctionnement et la structure d'algorithme.




Figure 25: Structure de l'algorithme random forest [26]

### • L'Algorithme de construction de Random forest

1. Sélectionnez des échantillons aléatoires à partir d'un ensemble de données d'entraînement.
2. Créer des arbres de décision pour chaque échantillon (sous-ensembles). Ensuite on obtient le résultat de prédiction de chaque arbre de décision
3. Pour les nouveaux points le vote sera effectué pour chaque résultat prédit.
4. sélectionnez le résultat de prédiction le plus voté comme résultat de prédiction final

#### a. Avantage de Random forest

1. Il s'agit de l'un des algorithmes d'apprentissage les plus précis disponibles. Pour de nombreux ensembles de données, il produit un classificateur très précis.
2. Il fonctionne efficacement sur de grandes bases de données.
3. Il dispose d'une méthode efficace pour estimer les données manquantes et maintient la précision lorsqu'une grande partie des données sont manquantes.[26]

#### b. Inconvénient de Random forest


Le principal inconvénient de l'algorithme random forest est qu'un grand nombre d'arbres peut rendre l'algorithme trop lent et inefficace pour les prédictions en temps réel. En général, ces algorithmes sont rapides à entraîner, mais assez lents à créer des prédictions une fois qu'ils sont formés. Une prévision plus précise nécessite plus d'arbres, ce qui entraîne un modèle plus lent.[26]

### C. Support Vector Machine (SVM)

Support vector machine (SVM) est l'une des méthodes les plus populaires dans la famille des approches supervisées et des méthodes de classification fondées sur les grains.

développé par Vapnik en 1995, et reste à ce jour l'un des algorithmes les plus populaires. Utilisé en particulier pour la reconnaissance de modèles.

### Exemple



**Figure 26:** Un simple exemple sur le fonctionnement de l'algorithme SVM

#### a. Avantage de SVM

1. Il a la capacité de gérer de grands espaces fonctionnels.
2. Fonctionne bien avec même des données non structurées et semi-structurées comme du texte, des images et des arbres.
3. Il s'adapte relativement bien aux données de grande dimension.

#### b. Inconvénient de SVM

1. Il est sensible au bruit
2. Difficile de comprendre et d'interpréter le modèle final, les poids variables et l'impact individuel.
3. L'extension de la classification à plus de deux classes est problématique.

#### D. Naïve\_Bayes

Naïve Bayésienne fait partie des algorithmes d'apprentissage automatique supervisé qui sont principalement utilisés pour la classification. C'est un classificateur probabiliste simple basé sur l'application de théorème de Bayes et qui aide à construire des modèles d'apprentissage automatique rapides qui peuvent faire des prédictions rapides. Naïve dans l'algorithme se réfère à l'hypothèse naïve que l'algorithme fait, qui est que chaque fonctionnalité est indépendante des autres fonctionnalités.[27]

**a. Théorème de Bayes**

Le théorème de Bayes (alternativement la loi de Bayes ou la règle de Bayes) décrit la probabilité d'un événement, basée sur la connaissance préalable des conditions qui pourraient être liées à l'événement. La formule est comme suit  $P(A/B) = P(B/A)P(A)/P(B)$

Où :  $P(A/B)$  : la probabilité conditionnelle que l'événement A se produise, étant donné que B s'est produit. Ceci est également connu comme la probabilité postérieure  $P(A)$  et  $P(B)$  : probabilité de A et B sans égard l'un à l'autre.[27]

**b. Avantage de naïve Bayes**

1. fonctionne également bien dans la prédiction multi-classes.
2. Lorsque l'hypothèse d'indépendance est vérifiée, un classificateur naïve Bayésienne fonctionne mieux que d'autres modèles.
3. Fonctionne mieux que les modèles plus compliqués lorsque l'ensemble de données est petit.[27]

**c. Inconvénient de naïve Bayes**

limitation de naïve Bayésienne est l'hypothèse de fonctionnalités indépendantes. Dans la vraie vie, il est presque impossible d'obtenir un ensemble de fonctionnalités complètement indépendants.[27]

**Conclusion**

Dans ce chapitre, nous présentons les derniers arts d'apprentissage automatique (qui est un sujet large et en constante évolution).

Tout d'abord, nous avons donné un bref aperçu historique de l'émergence du domaine, puis nous avons donné ses différents types et certains algorithmes utilisés (algorithmes mis en œuvre par différentes sources d'inspiration, allant de la théorie des probabilités à l'intuition géométrique aux méthodes expérimentales). Avant de conclure ce cours, nous avons décrit comment tester et valider les modèles ML.

## **Chapitre III : Traitement d'image**



## Introduction

La segmentation peut distinguer les objets d'intérêt dans une image en les isolant de l'arrière-plan ou d'autres objets. Après segmentation d'une image, chaque pixel se voit attribuer une région, et chaque région correspond à une partie sémantique de l'image. Les discontinuités entre régions correspondent aux contours des objets. Les méthodes de segmentation peuvent être divisées en deux catégories. D'un côté, les contours se rapprochent. De l'autre côté, la zone s'approche. Malgré la variété des méthodes, il est encore difficile de déterminer l'homogénéité au sein de l'image, comme en définit globalement un seuil d'homogénéité simple recommandé dans certaines méthodes de segmentation classiques (comme la croissance de région), et en fait cette homogénéité peut être à des degrés divers et ceci dans différentes parties de l'image.

Nous allons introduire quelques techniques relevant de ce traitement en passant dans un rappel sur le traitement d'image puis en passant à la segmentation.

### III.1 Rappels sur la notion d'image

Une image réelle est obtenue à partir d'un signal continu bidimensionnel comme par exemple un appareil photo ou une caméra... Sur un ordinateur, on ne peut pas représenter de signaux continus, on travaille donc sur des valeurs discrètes.

### III.2 Définition de l'image

L'image est définie comme étant une fonction  $f(x,y)$  à deux dimensions, où  $x$  et  $y$  sont les coordonnées spatiales, et  $f$  l'amplitude à tous points  $(x,y)$  correspondant à l'intensité ou au niveau de gris. Lorsque les points  $(x,y)$  et l'amplitude sont discrétisés, on parle d'image numérique ou digitale. Dans ce dernier cas la fonction  $f$  est remplacée par la lettre  $I$  et le couple  $(x,y)$  par le couple  $(i,j)$ .

#### III.2.1 Image binaire

Une image binaire est une image  $M \times N$  où chaque point peut prendre uniquement la valeur 0 ou 1. Les pixels sont noirs (0) ou blancs (1). Le niveau de gris est codé sur un bit (Binary digIT). Avec  $N_g = 2$  et la relation sur les niveaux de gris devient :  $p(i,j) = 0$  ou  $p(i,j) = 1$ .

### III.2.2 Image en niveaux de gris

Le niveau de gris est la valeur de l'intensité lumineuse en un point. La couleur du pixel peut prendre des valeurs allant du noir au blanc en passant par un nombre fini de niveaux intermédiaires. Le nombre de niveaux de gris dépend du nombre de bits utilisés pour décrire la " couleur " de chaque pixel de l'image. Plus ce nombre est important, plus les niveaux possibles sont nombreux.

### III.2.3 Image couleur (RGB)

La représentation des couleurs s'effectue de la même manière que les images monochromes avec cependant quelques particularités. En effet, il faut tout d'abord choisir un modèle de représentation. On peut représenter les couleurs à l'aide de leurs composantes primaires. Les systèmes émettant de la lumière (écrans d'ordinateurs...) sont basés sur le principe de la synthèse additive : les couleurs sont composées d'un mélange de rouge, vert et bleu (modèle R.v.B.) [29],[28].

### III.2.4 Image indexée

la plupart des images n'utilisent pas les 16 millions de couleurs possibles, pour un besoin de stockage et de gestion de fichier, l'image à une palette de couleur qui représente la liste des couleurs qu'elle utilise. La valeur du pixel est un index dans cette palette.

Comme l'indique, l'indice 6 pointe vers la palette de couleur qui fournit la proportion de chaque couleur de base (R, G, B).




Figure 27: Image couleur indexée.

## III.3 Caractéristiques de l'image numérique

L'image est un ensemble structuré d'informations caractérisées par les paramètres suivants :

### III.3.1 Pixel

Une image est constituée d'un ensemble de points appelés pixels. Le pixel (picture element) représente ainsi le plus petit élément constitutif d'une image numérique. La quantité d'information que véhicule chaque pixel donne des nuances entre images monochromes et images couleurs. Pour les images 3D le « pixel » est alors appelé un voxel, et représente un volume élémentaire. Des exemples d'images de ce type se rencontrent dans les images médicales. Les images tomographiques axiales sont ainsi des images construites à partir de plusieurs radiographies faites sous des angles de vue différents.[30]



*Figure 28:* représentation de pixel.[31]

La lettre A, par exemple, peut être affichée comme un groupe de pixels dans la figure ci-dessous :



*Figure 29:* L'image comme un groupe de pixels.

### III.3.2 Définition de l'histogramme

C'est la représentation graphique - par un diagramme en bâtons ou « paragraphe » - des classes d'une variable statistique, associant à chaque classe un rectangle proportionnel par sa longueur à l'amplitude, par sa hauteur à l'effectif de cette classe.

En photo numérique, l'histogramme d'une image indique dans l'axe horizontal (axe des abscisses) le nombre de différentes valeurs de luminosité que peut prendre un pixel (soit de 0 à

255 en 8-bit) et en verticale (axe des ordonnées) le nombre des pixels qui ont la même valeur discrète.




Figure 30 : Histogramme d'image

### III.3.3 Contours et textures

Les contours représentent la frontière entre les objets de l'image, ou la limite entre deux pixels dont les niveaux de gris représentent une différence significative. Les textures décrivent la structure de ceux-ci. L'extraction de contour consiste à identifier dans l'image les points qui séparent deux textures différentes.

### III.3.4 Dimension

C'est la taille de l'image. Cette dernière se présente sous forme de matrice dont les éléments sont des valeurs numériques représentatives des intensités lumineuses (pixels). Le nombre de lignes de cette matrice multiplié par le nombre de colonnes nous donne le nombre total de pixels dans une image.[31]

### III.3.5 Bruit

Un bruit (parasite) dans une image est considéré comme un phénomène de brusque variation de l'intensité d'un pixel par rapport à ses voisins, il provient de l'éclairage des dispositifs optiques et électroniques du capteur.[31]

### III.3.6 Luminance

C'est le degré de luminosité des points de l'image. Elle est définie aussi comme étant le quotient de l'intensité lumineuse d'une surface par l'aire apparente de cette surface, pour un observateur lointain, le mot luminance est substitué au mot brillance, qui correspond à l'éclat d'un objet. Une bonne luminance se caractérise par :

1. **Des images lumineuses** (brillantes) :

2. **Un bon contraste** : il faut éviter les images où la gamme de contraste tend vers le blanc ou le noir : ces images entraînent des pertes de détails dans les zones sombres ou lumineuses.

3. **L'absence de parasites.**

### III.3.7 Contraste

C'est l'opposition marquée entre deux régions d'une image, plus précisément entre les régions sombres et les régions claires de cette image. Le contraste est défini en fonction des luminances de deux zones d'images. [32]

Si  $L_1$  et  $L_2$  sont les degrés de luminosité respectivement de deux zones voisines  $A_1$  et  $A_2$  d'une image, le contraste  $C$  est défini par le rapport.

### III.3.8 Région

Une région est un ensemble de pixels connexes et homogènes. Un pixel n'appartient à une région donnée que s'il vérifie les caractéristiques de celle-ci (intensité moyenne, centre de gravité, ...). Une région est toujours limitée par un contour.

### III.3.9 Connexité

En traitant une image, on est souvent amené à se déplacer dans celle-ci. Un déplacement doit souvent obéir à des règles de voisinage, on utilise généralement deux types de voisinage : le voisinage à 4-connexité (4 pixels voisins) et le voisinage à 8-connexité (8 pixels voisins).





Figure 31: Voisinages (a) 8-connexité (b) 4-connexité

## III.4 La Segmentation d'image

Le traitement d'images est une discipline de l'informatique et des mathématiques appliquées qui étudie les images numériques et leurs transformations, dans le but d'améliorer leur qualité ou d'en extraire de l'information. La segmentation d'images est une étape importante et primordiale dans le processus de traitement et d'analyse d'images qui a pour but

de partitionner une image en régions homogènes et regrouper des pixels ayant des propriétés communes suivant des critères prédéfinis. La figure suivante représente un exemple de segmentation d'images.



*Figure 32:* Segmentation d'une image couleur

### **III.4.1 Définition de la segmentation d'images**

La segmentation est une des étapes critiques de l'analyse d'images qui conditionne la qualité des traitements d'images effectués ultérieurement. Elle permet d'isoler dans l'image les objets sur lesquels doit porter l'analyse, de séparer, dans une image, les régions d'intérêt du fond.

En effet, à partir des résultats de la segmentation, il est possible d'identifier les objets d'une scène. Par rapport aux images en niveaux de gris, la segmentation d'images couleur est un domaine de recherche assez récent. En effet, pendant plusieurs années beaucoup d'attention a été focalisée sur la segmentation d'images en niveaux de gris. La segmentation peut être manuelle ou automatique.

### **III.4.2 les approches de segmentation**

Généralement, les méthodes de segmentation sont regroupées en trois approches chacune ayant des avantages et ses domaines d'application et elles sont parfois complémentaires, ces approches sont :

1. **Segmentation basée sur les contours** (en anglais : edge-based segmentation).
2. **Segmentation basée sur les régions** (en anglais : régions-based segmentation).
3. **Segmentation en utilisant la classification.**




Figure 33: approche région et approche contour.

## A. Approches contour

### a. Définition

Dans une image, un contour peut être considéré de différentes manières. Nous allons décrire ici trois principales manières de considérer un contour : Premièrement, un contour peut être vu comme un changement brusque de l'intensité de l'image existe plusieurs types de variations comme le montre la figure.[37]




Figure 34: Profil de contours (marche, rampe, toit, pic).




Figure 35 : Quelques modèles de contours

- **Marche d'escalier** : le contour est net (contour idéal).
- **Rampe** : le contour est plus flou.
- **Toit** : il s'agit d'une ligne sur un fond uniforme.

Deuxièmement, une façon très proche de celle citée ci-dessus est de considérer les contours comme une différence sur la couleur. Troisièmement, si on considère l'image comme étant un signal 2D, on peut passer dans le domaine fréquentiel (par transformée de Fourier ou d'ondelette par exemple).

## **B. Approche région**

La segmentation d'image par l'approche région est une méthode de segmentation d'image qui consiste à diviser une image en régions homogènes ou en groupes de pixels qui partagent des caractéristiques similaires telles que la couleur, la texture, la luminosité ou la forme. Cette approche est souvent utilisée pour des tâches telles que la détection d'objets, la reconnaissance de formes et la séparation de l'avant-plan et de l'arrière-plan. Il existe différentes techniques pour effectuer la segmentation d'image par l'approche région. L'une des plus courantes est l'algorithme de segmentation de Watershed. Cette méthode utilise une approche basée sur les gradients pour diviser l'image en régions. L'algorithme commence par trouver les lignes de contour de l'image, puis il les utilise pour diviser l'image en bassins versants, qui sont des régions qui suivent les contours de l'image. Les bassins versants sont ensuite fusionnés en fonction de critères tels que la similarité de couleur et de texture. Une autre technique courante pour la segmentation d'image par l'approche région est l'algorithme de croissance de région. Cette méthode commence par sélectionner un pixel de départ dans l'image, puis elle agrandit la région en ajoutant des pixels qui partagent des caractéristiques similaires avec le pixel de départ. Le processus se poursuit jusqu'à ce que la région atteigne une frontière, qui peut être déterminée en utilisant des critères tels que la variation de couleur ou la texture.

En général, la segmentation d'image par l'approche région peut être un processus complexe et sujet à des erreurs, en particulier lorsque les images sont complexes ou contiennent des éléments qui se chevauchent ou se confondent. Cependant, avec les techniques et les algorithmes appropriés, cette approche peut être très efficace pour de nombreuses applications de traitement d'image.[37]

### **a. Segmentation par fusion de régions (MERGE)**

La segmentation par fusion de régions, également appelée segmentation par fusion, est une technique de traitement d'images qui consiste à regrouper des régions adjacentes qui présentent des caractéristiques similaires. Cette technique permet de simplifier la représentation d'une image en réduisant le nombre de régions distinctes. Le processus de segmentation par fusion de régions implique généralement les étapes suivantes :

- **Définition des régions initiales :** La première étape consiste à définir des régions initiales de l'image. Cela peut être fait en utilisant une technique de segmentation initiale, telle que la segmentation par seuillage.



- **Calcul des attributs de région** : Les caractéristiques de chaque région sont calculées, telles que la couleur, la texture, la forme et la taille.

- **Calcul de la similarité entre les régions** : La similarité entre les régions est calculée en fonction des caractéristiques calculées à l'étape précédente. Fusion des régions : Les régions adjacentes qui présentent des similitudes supérieures à un certain seuil sont fusionnées pour former des régions plus grandes. Répéter les étapes 2 à 4 jusqu'à ce qu'un critère d'arrêt soit satisfait :


Les étapes 2 à 4 sont répétées jusqu'à ce qu'un critère d'arrêt soit satisfait, tel que le nombre de régions restantes ou le niveau de similarité entre les régions. La segmentation par fusion de régions est souvent utilisée dans des applications telles que la reconnaissance de formes, l'analyse d'images médicales et la vision par ordinateur. Cependant, cette technique peut être sensible aux conditions initiales et aux paramètres de seuil, et peut être limitée par la complexité des images segmentées.

### **b. Segmentation par division de régions (SPLIT)**

La division consiste à partitionner l'image en régions homogènes selon un critère donné. Le principe de cette technique est de considérer l'image elle-même comme région initiale, qui par la suite est divisée en régions. Le processus de division est réitéré sur chaque nouvelle région (issue de la division) jusqu'à l'obtention de classes homogènes. Cette méthode présente un inconvénient majeur qui est la sur-segmentation. Toutefois, ce problème peut être résolu en utilisant la méthode de division-fusion que nous présentons dans ce qui suit.

### **C. Segmentation par division-fusion (SPLIT+Merge)**

Ces méthodes combinent les deux méthodes décrites précédemment, la division de l'image en de petites régions homogènes, puis la fusion des régions connexes et similaires au sens d'un prédicat de regroupement. Deux régions seront fusionnées si elles répondent aux critères de similarité des niveaux de gris et d'adjacence de régions. On s'arrête quand le critère de fusion n'est plus vérifié.



**Figure 36** : Agrégation itérative des blocs similaires au bloc 1.

### **III.4.3 Les inconvénients de cette méthode se situent à trois niveaux**

- Les limites des régions obtenues sont habituellement imprécises et ne coïncident pas exactement aux limites des objets de l'image.
- La difficulté d'identifier les critères pour agréger les pixels ou pour fusionner et diviser les régions.

### **III.5 Quelques algorithmes de segmentation d'images**

#### **III.5.1 Algorithmes de classification de pixels non-supervisée :[33]**

Nous allons à présent présenter trois des algorithmes de classification de pixels non supervisée à savoir :

- a. L'algorithme des k-moyennes.
- b. L'algorithme des C-moyennes floues.
- c. L'algorithme de Fisher

#### **III.5.2 Algorithmes de classification de pixels supervisée**

Nous allons à présent présenter quatre algorithmes de classification de pixels supervisée à savoir :

- a. Algorithme des k-plus proches voisins.
- b. Algorithme de Bayes.
- c. Algorithme des Machines à support de vecteurs.
- d. Algorithme des Réseaux de Neurones Multi Couches.

### **III.6 Objectifs de la segmentation**

- Fournir des régions homogènes (selon un critère donné).
- Localiser de manière précise les contours des régions.
- L'étude et l'interprétation des structures anatomiques.
- Réduction de bruit. [34]

### **III.7 Segmentation sémantique d'images**

• **conduite autonome** : La conduite autonome, également connue sous le nom de conduite automatisée, est une technologie émergente qui permet à un véhicule de se déplacer sans l'intervention d'un conducteur humain. Cette technologie est rendue possible grâce à l'utilisation de capteurs, de caméras, de lidars et de logiciels sophistiqués qui permettent au véhicule de percevoir son environnement, de prendre des décisions et d'agir en conséquence. Les véhicules autonomes peuvent être classés en fonction de leur niveau d'automatisation. L'Organisation internationale de normalisation (ISO) définit six niveaux d'automatisation, allant de 0 (aucune automatisation) à 5 (automatisation complète).

• **Industriels** : pour détecter les défauts dans des matériaux, comme le contrôle des composants électroniques.

• **Imagerie satellite** : Pour identifier les montagnes, les rivières, les déserts et autres terrains.

• **Imagerie médicale** : Pour analyser et détecter les anomalies cancéreuses dans les cellules.

• **Vision robotique** : Pour identifier les objets et le terrain et s'y déplacer.

### **III.8 La classification d'image**

#### **III.8.1 Méthodes de classification d'images**

La classification est une tâche qui tente à identifier les objets en se basant sur certaines de leurs caractéristiques. Par exemple, pour pouvoir utiliser les images pour les analyses complémentaires ou pour la cartographie, il est souvent important de traduire l'information de fréquence contenue dans les images en information thématique portant sur l'occupation du sol ou la couverture végétale. On a généralement le choix entre **deux approches** : la **classification supervisée** et **non supervisée**. [35]

#### **III.8.2 L'objectif de la classification**

L'objectif de la classification est de regrouper des éléments similaires en catégories distinctes et de distinguer les éléments différents en groupes séparés. Cela permet de simplifier et d'organiser de grandes quantités de données, ce qui facilite l'analyse, la compréhension et la prise de décision. La classification peut être utilisée dans de nombreux domaines, tels que la biologie, la linguistique, l'informatique, l'économie et la sociologie, entre autres. Elle est souvent utilisée pour identifier des modèles et des relations cachées dans

les données, pour prédire des résultats futurs ou pour aider à la prise de décision dans des situations complexes. Il existe plusieurs méthodes de classification, notamment la classification supervisée, qui utilise des exemples étiquetés pour entraîner un modèle de classification, et la classification non supervisée, qui regroupe les éléments similaires sans étiquetage préalable. [35]

### **III.8.3 Domaines d'application de la classification**

La classification est une méthode d'analyse de données qui consiste à regrouper des éléments similaires en catégories ou classes distinctes. Cette technique est utilisée dans de nombreux domaines d'application pour aider à organiser et à comprendre des données complexes. Voici quelques exemples de domaines d'application de la classification [36]

**1. La biologie :** La classification est utilisée pour classer les espèces vivantes en groupes taxonomiques basés sur des caractéristiques communes, telles que la morphologie, le comportement ou le patrimoine génétique.

**2. La santé :** La classification est utilisée pour diagnostiquer des maladies, évaluer les risques de santé et aider à prescrire des traitements. Les systèmes de classification sont utilisés pour classer les symptômes, les maladies et les traitements en catégories distinctes.

**3. La finance :** La classification est utilisée pour l'analyse des risques et l'attribution d'actifs dans les portefeuilles d'investissement. Les investisseurs peuvent classer les actifs en fonction de leur profil de risque et de leur rendement pour construire un portefeuille équilibré.

**4. L'informatique :** La classification est utilisée pour la reconnaissance de formes et l'apprentissage automatique. Les algorithmes de classification sont utilisés pour classer des images, des sons ou des données textuelles en fonction de leurs caractéristiques communes.

**5. La géographie :** La classification est utilisée pour cartographier les données géographiques et pour comprendre la répartition spatiale des phénomènes.

Les scientifiques peuvent classer les données géographiques, telles que les types de sol, les zones climatiques ou les populations animales, pour en tirer des conclusions sur les modèles et les tendances.

**6. Les sciences sociales :** La classification est utilisée pour la catégorisation des individus en fonction de leurs caractéristiques socio-économiques ou démographiques, comme le sexe, l'âge, l'éducation ou le niveau de revenu.

Les enquêtes peuvent utiliser des systèmes de classification pour analyser les tendances et les relations entre les variables. En résumé, la classification est une technique d'analyse de

données qui est largement utilisée dans une grande variété de domaines pour organiser, comprendre et tirer des conclusions à partir de données complexes.[36]

### **Conclusion**

La segmentation d'une image se distingue en deux approches (région et contour), L'approche contour, par exemple, nécessite souvent un algorithme de fermeture du contour. L'approche région est, quant à elle, généralement plus gourmande en calcul.

# **Chapitre IV : Généralités sur le cancer du sein**

## **Introduction**

Le cancer du sein est un problème de santé publique : il est la première cause de décès par cancer chez les femmes. Il semble être moins fréquent chez les femmes plus jeunes, mais 25 % des cas surviennent avant l'âge de 50 ans. Le dépistage de masse mis en place concerne les femmes de plus de 50 ans. Avant cet âge, le dépistage comprend un suivi gynécologique annuel, incluant des examens des seins. De plus, les femmes entre 40 et 50 ans peuvent bénéficier d'un dépistage individuel par mammographie.

Le cancer du sein est le cancer féminin le plus fréquent, il représente la première pathologie cancéreuse chez la femme et constitue chez elle une cause majeure de décès prématuré. Tout au long de ce chapitre nous allons mettre l'accent sur cette pathologie puisqu'elle est très répandue dans le monde entier, nous allons la définir, donner un aperçu historique, présenter ses différentes classifications ainsi que ses facteurs de risques, dépistage, son diagnostic et ses différents traitements et enfin la surveillance.

### **IV.1 Définition**

Le cancer du sein est causé par la destruction de certaines cellules qui se multiplient et forment le plus souvent une masse appelée tumeur. Il en existe différents types qui n'évoluent pas de la même manière. Certains sont "agressifs" et évoluent très vite, d'autres plus lentement. Les cellules cancéreuses peuvent rester dans le sein. Ils peuvent également se propager à d'autres organes, une condition plus menaçante. Ensuite, on parle de transferts. Dans la plupart des cas, il faut des mois, voire des années, pour qu'un cancer du sein se développe. Le cancer du sein est le cancer le plus fréquent chez les femmes. Il représente plus d'un tiers de tous les nouveaux cas de cancer chez les femmes. Les organes les plus fréquemment atteints par les métastases sont les poumons, le foie et le cerveau. On connaît deux catégories générales de tumeurs :

- Les tumeurs bénignes
- Les tumeurs malignes ou cancers [37]

Tumeurs bénignes	Tumeurs malignes
Bien limitée	Mal limitée
Encapsulée	Non Encapsulée
Histologiquement semblable au tissu d'origine	Plus ou moins semblable au tissu d'origine (Dédifférenciation, dédifférenciation aberrante)
Cellules régulières	Cellules irrégulières (cellules cancéreuses)
Croissance lente	Croissance rapide
Refoulement sans destruction des tissus voisins	Envahissement des tissus voisins
Pas de récurrence locale après exérèse complète	Récurrence possible après exérèse supposée totale
Pas de métastase	Métastase(s)

**Tableau 2:** Critères de distinction entre tumeurs bénignes/ malignes.[38]

## IV.2 Les caractéristiques du cancer du sein

Le cancer du sein est une tumeur maligne qui se développe à partir des cellules du sein. Si le cancer du sein n'est pas traité, les cellules tumorales se propagent localement et envahissent les organes adjacents (expansion locale puis expansion régionale). Ils peuvent également se propager (généralement se propager) à des organes distants (métastaser) par les voies sanguines ou lymphatiques. Les organes les plus fréquemment touchés par les métastases sont les os, les poumons, le foie et le cerveau. Au premier stade, le cancer du sein est trop petit pour être détecté par la palpation des seins ou des tests de dépistage (mammographie, échographie). Il n'a aucun symptôme à ce stade.



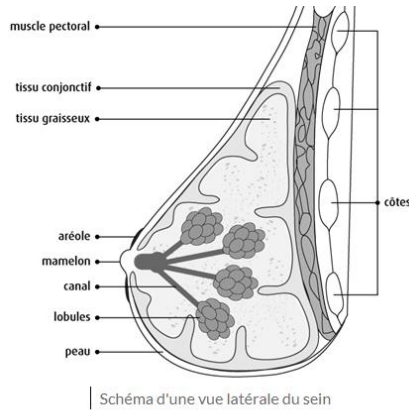


Figure 37c: schéma d'une vue latérale du sein.[39]

### IV.3 Classification de cancer de sien

#### IV.3.1 Classification Clinique

La classification TNM permet de définir le cancer en stade. Elle basée sur :

- la taille de la tumeur (T)
- le caractère invasif ou non invasif du cancer
- l'atteinte des ganglions lymphatiques (N)
- l'extension du cancer au-delà du sein : les métastases (M).

Tumeur Primare (T)	
T0	Tumeur primitive non palpable
T1	Tumeur $\leq 2$ cm dans sa plus grande dimension
T2	$2\text{cm} \leq$ Tumeur $\leq$ dans sa plus grande dimension
T3	Tumeur $\leq 5$ cm dans sa plus grande dimension
Ganglions lymphatiques régionaux pN	
N0	Absence d'envahissement ganglionnaire régional histologique et absence d'examen complémentaire à la recherche de cellules tumorales isolées
N1	Envahissement de 1 à 3 ganglion axillaires ou/et envahissement des ganglions de la CMI détecter sur ganglion sentinelle sans signe clinique

<b>N2</b>	Envahissement de 7 à 9 ganglions axillaires ou envahissement des ganglions mammaires internes sur homolatéraux suspects, en l'absence d'envahissement ganglions axillaires
<b>N3</b>	Envahissement d'au moins 10 ganglions axillaires ou envahissement des ganglions sous-claviculaires (niveau III axillaire) ou envahissement des ganglions mammaires internes homolatéraux suspects avec envahissement ganglionnaire axillaires ou envahissement de plus de 3 ganglions axillaires et envahissement des ganglions de la CMI détecté sur ganglion sentinelle sans signe clinique ou envahissement des ganglions sous-claviculaires homolatéraux
<b>Métastases à distance (M)</b>	
<b>M0</b>	Absence de métastases à distance
<b>M1</b>	Présence de métastases(s) à distance

*Tableau 3: Classification TNM.*

### **IV.3.2 La classification histopathologies du cancer du sein**

Dans plus de 95 % des cancers du sein, la tumeur se développe à partir des cellules épithéliales glandulaires et sont appelés adénocarcinomes (ou carcinome). Selon sa localisation elle peut être qualifiée de canalaire (85 à 90% des cas) et se développer à partir d'un canal galactophore ou lobulaire (10 à 15% des cas) et se développer dans un lobule.[40]

### **IV.3.3 la classification moléculaire du cancer du sein**

Quatre sous types de cancers du sein sont ainsi définis : Luminal A, luminal B, HER2+ et triple négatif (RE-, RP-, HER2-) Cette classification a une valeur pronostic et une valeur prédictive de réponse thérapeutique et va guider la stratégie thérapeutique à employer.

	Lminal A	Luminal B	HER2+	Triple -
Expression RE/RP	RE+++ ET/OU RP+++	RE+ et/ou RP+	RE-/RP-	RE-/RP-
Expression HER2	HER2-	HER2+/-	HER2+	HER2-
Expression ki-67	Ki-67 faible < 20 %	Ki-67 élevé > 20 %		
Fréquence	60 %	10 %		
Pronostic	Bon ++	Bon	Mauvais	Mauvais
Impact sur la thérapeutique	Forte sensibilité l'HT faible sensibilité de la CT	Sensibilité à l'HT variable Bonne sensibilité à la CT	Traitement anti-HER2 Bonne sensibilité à la CT	Traitement par CT

**Tableau 4:**Classification moléculaire des différents sous-types de cancer du sein. [40]

#### IV.4 Les types de cancer du sein

Il existe différents types de cancer du sein qui sont définis au niveau histologique.

##### IV.4.1 Le cancer in Situ

Ils sont définis par des proliférations cancéreuses qui se développent dans la lumière des canaux et des folioles, ne pénètrent pas la membrane basale et n'envahissent pas le tissu conjonctif. [41], [42]

### **A. Carcinome canalaire in situ (intra-canalaire)**

Elle correspond à la prolifération de cellules malignes des canaux galactophores qui n'infiltrent pas le tissu conjonctif. Cela représente une évolution possible vers l'invasion, et l'agressivité est variable. [41],[42]

### **B. Carcinome lobulaire in situ (intra-lobulaire)**


Il correspond à un carcinome impliquant des tubules intra-lobulaires qui se remplissent et se dilatent du fait de la prolifération de cellules mal alignées sans envahir le tissu conjonctif adjacent. Dans de nombreux cas, il se développe en un cancer invasif. [41 ; 42]

## **IV.4.2 Le cancer Infiltrant**

Dans ce cas, les cellules tumorales envahissent le tissu conjonctif et peuvent donner des métastases. Parmi les formes infiltrantes, on distingue la forme commune, le carcinome canalaire infiltrant, qui représente 75 % des cas. [41,42]

Les autres formes infiltrantes sont plus rares :


- Carcinome canalaire infiltrant avec une composante intra-canalaire prédominante
  - Carcinome lobulaire infiltrant (le moins rare)
  - Carcinome mucineux ou colloïde muqueux
  - Carcinome médullaire
  - Carcinome tubuleux
  - Carcinome cribriforme infiltrant
  - Carcinome papillaire infiltrant
  - Carcinome adénoïde kystique
  - Carcinome apocrine
  - Carcinome sécrétant
  - Carcinome métaplasique [...]



**Figure 38:** le sein Normal et le sein Anormal

### A. Les masses

Ce sont des lésions retrouvées en trois dimensions. Plus dense que le tissu Seins adjacents, qui apparaissent blancs sur une mammographie. Taille imprévisible Pas un trait malin à moins que les stéréotypes successifs montrent une augmentation régulière couper. On distingue traditionnellement cinq formes différentes de touffes rondes, ovales, Lobulaire, irrégulier ou structurellement déformé. La dernière forme comprend la lumière converge vers un point où la mise au point se rétrécit. La figure montre un ensemble de lésions.



**Figure 39 :** Les types de masses

## IV.5 Epidémiologie du cancer de sein

### IV.5.1 Indice et mortalité

#### A. Dans le monde

Depuis plusieurs années, le cancer du sein est devenu un enjeu majeur de santé publique dans le monde, nécessitant la mise en place d'actions de prévention et de dépistage. Selon les dernières statistiques, plus de 2 millions de nouveaux cas de cancer du sein sont diagnostiqués chaque année chez les femmes dans le monde. Environ 7 millions de femmes vivent avec un cancer du sein diagnostiqué au cours des 5 années précédentes, il représente le cancer le plus

fréquemment diagnostiqué chez les femmes dans 156 pays parmi les 185 couverts par GLOBOCAN dans le monde.

Selon, GLOBOCAN et l'American Cancer Society (ACS), ce cancer représente 25% des nouveaux cancers diagnostiqués chez les femmes à l'échelle mondiale. Il constitue une préoccupation majeure pour tous les Etats, en raison de l'augmentation de son incidence. Les taux d'incidence ajustés pour l'âge varient, selon les régions du monde. Les taux annuels les plus bas (inférieurs à 40 pour 100000 femmes) sont enregistrés en Asie et en Afrique, les taux intermédiaires (entre 50 et 65 pour 100000) sont observés en Amérique de Sud et en Europe de l'Est, les taux les plus élevés (plus de 70 pour 100000) affectent l'Europe de l'Ouest et l'Amérique de Nord.

Le cancer de sein compte parmi les principales causes de décès par cancer chez les femmes (15.0 %).

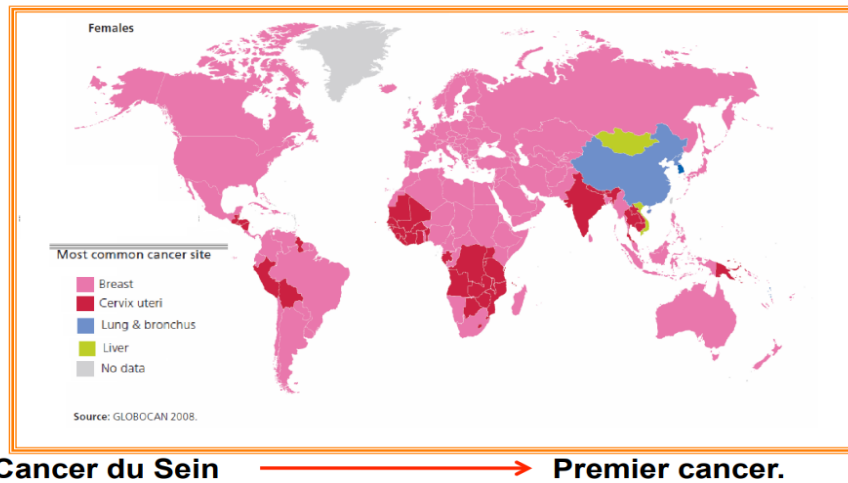
- **En Europe**, le cancer du sein reste le plus fréquent avec 522531 nouveaux cas, une incidence standardisée estimée à 74.4/100000 femmes en 2018, il représente la 1<sup>ère</sup> cause de décès avec 137.707 cas.[43]

- **La France**, a enregistré 65162 nouveaux cas et 13353 décès annuels. Aux Etats-Unis d'Amérique (USA) et même au Canada, 1 femme sur 8 sera touchée par le cancer du sein.

- **En Tunisie**, chaque année 2000 nouveaux cas de cancers du sein sont diagnostiqués soit une incidence standardisée de 32/100000 femmes par an. En Egypte, plus de 23000 cas de cancer du sein sont diagnostiqués avec une incidence de 52.4/10000 femmes.[44]

- **Pour les pays du Maghreb**, et ceux du Moyen-Orient, le cancer de sein est également le premier cancer de la femme. Il représente 14 à 42 % de tous les cancers féminins avec une augmentation exponentielle. Son incidence standardisée selon l'âge (ISA) varie entre 9.5 et 54 pour 100000 femmes. L'Organisation mondiale de la santé (OMS) considère le cancer du sein comme une priorité de santé publique et un problème majeur chez la femme dans cette région du monde.

L'incidence élevée des cancers du sein chez la femme jeune dans les pays du Maghreb, représente une réalité épidémiologique en comparaison avec d'autres registres.[44]



**Figure 40:** Cancers féminins (mortalité, répartition mondiale) [45]

## B. En Algérie

**En Algérie**, le cancer du sein est considéré comme étant le premier cancer de la femme, et même la première cause de mortalité par cancer avec 11847 nouveaux cas enregistrés annuellement, et 3367 décès, un taux d'incidence standardisée estimée à 55.6/10000 femmes et une mortalité de 16.2/10000 femmes.

Il garde sa première place parmi les différentes localisations chez la femme dans tous les registres de cancer (celui d'Oran, de Tlemcen, de Sétif et d'Alger).


Les incidences varient selon les registres des cancers, celui d'Alger a enregistré une incidence standardisée de 69.7/100000 femmes en 2014, celui d'Oran, le taux d'incidence est 22 passé de 26/100000 femmes en 2000 à 40/100000 femmes en 2004 à 63/100000 femmes en 2015, pour Sétif, l'incidence avoisine les 49.2/100000 femmes en 2010.

Il n'existe pas beaucoup de différences en termes d'incidence et mortalité entre les pays du Maghreb. A Oran, selon le registre du cancer de la population d'Oran, entre la période de 2005 et 2014, on a enregistré 3952 cas de cancer du sein chez la femme, il est classé au 1<sup>er</sup> rang de tous les cancers de la femme.

Il représente une fréquence de 21% par rapport à l'ensemble des cancers (n=18870) cas (toutes localisations confondues et chez les deux sexes). [45]

L'âge moyen est de 47+- 0.4 ans, il touche de plus en plus la femme jeune, le type morphologique le plus retrouvé est le carcinome canalaire infiltrant chez = 70% des patientes.

Son incidence ne cesse d'augmenter, elle passe de 27.1/100000 pour la période de 1996 à 2004 à 43.0/100000 habitants pour la période de 2005 à 2016.



**Figure 41:** Evolution annuelle des fréquences du cancer du sein féminin RCO 1996-2016

### IV.5.2 Survie

La survie des patients atteints de cancer s'améliore grâce en particulier à des diagnostics plus précoces et des traitements plus efficaces. Ce constat est fait en Europe et en Amérique du nord. Le taux de survie est lié à la localisation du cancer et à son stade au moment du diagnostic. Ainsi, mais des cancers ayant des pronostics différents.

Certains cancers guérissent, alors que d'autres conservent un pronostic sombre ou bien évoluent à long terme, telles des maladies chroniques.

**En France**, il y a eu une amélioration de la survie à 5 ans passant de 80 % au cours de la période (1989-1993) à 87% (2005-2010), par contre en Algérie la survie reste toujours basse malgré son amélioration puisqu'elle est passée de 17% (1995-1999) à 29% (2000-2004) à 59% (2005-2009).[40]

### IV.6 Facteurs des risques du cancer du sein

Les cancers sont des maladies le plus souvent multifactorielles, ce qui est le cas pour les cancers du sein. Un certain nombre de facteurs de risques ont été identifiés, mais il persiste encore aujourd'hui des incertitudes sur leur poids dans le processus de cancérogenèse. Malgré l'identification de ces facteurs de risques, il est impossible de prédire individuellement avec certitude l'apparition d'un cancer même s'il est possible d'identifier une population plus à risque. La connaissance de ces facteurs de risque permet de mettre en œuvre des actions de prévention.



### IV.6.1 Facteurs des risques intrinsèques

#### 1. L'âge

Le risque de développer un cancer augmente avec l'âge, et cela est valable pour le cancer du sein même s'il peut survenir dans un intervalle d'âge très large. En France, environ 20-30 % des cancers du sein se manifestent avant 50 ans, 50-60 % entre 50 et 69 ans et 10-20 % après 70 ans.

Risque d'avoir un K Sein selon âge




Figure 42 : Incidence et mortalité du cancer du sein par âge

#### 2. Le sexe

Le sexe constitue le principal facteur de risque de cancer du sein, puisque 99 % des sujets atteints sont des femmes. Cela montre l'importance de l'imprégnation hormonale dans le développement des cancers du sein.

#### 3. Les antécédents familiaux, personnels et l'hérédité génétique

L'interrogatoire d'une patiente atteinte d'un cancer du sein comporte toujours des questions concernant l'historique familial des cancers, particulièrement gynécologiques. En effet, le risque de développer un cancer du sein augmente si au minimum un membre de la famille proche a déjà eu un cancer du sein à un âge précoce (avant 50 ans).

En cas de suspicion de cancer familial, une enquête génétique permettra l'analyse du génome du patient atteint afin de rechercher des mutations germinales héréditaires touchant des gènes suppresseurs de tumeurs. Les mutations sur les gènes BRCA1 et BRCA2 sont responsables de la majorité des cancers du sein héréditaires. Leur présence est associée à un risque augmenté de développer un cancer du sein (y compris chez les hommes) et un cancer ovarien. Elles sont transmises selon un mode autosomique dominant avec une pénétrance qui varie en fonction du gène atteint. Le risque de développer un cancer du sein héréditaire varie

de 65 % en cas de mutation BCRA1 à 45 % en cas de mutation BRCA2. Les cancers du sein familiaux apparaissent souvent à un jeune âge et les porteuses de ces mutations ont à l'âge de 70 ans jusqu'à 80 % de risque de développer un cancer du sein ; ce risque est de 6 % pour les hommes.

Les personnes porteuses d'une mutation BRCA se voient proposer une prise en charge spécifique, basée sur des actions prophylactiques de surveillance, voire de chirurgie en cas de risque élevé : mastectomie bilatérale associée ou non à une ovariectomie. La survie à 5 ans des patients ayant un cancer du sein avec mutation BRCA est identique à celles n'ayant pas de mutation prédisposante.[46]

## **IV.6.2 Facteurs de risques extrinsèques**

### **A. Obésité et prise de poids**

Avant la ménopause, le risque de cancer du sein semblerait diminué car l'obésité engendre des cycles menstruels anovulatoires ; cependant, à partir de la ménopause, le risque s'accroît fortement car l'excès de tissu adipeux entraîne la production d'œstrogènes via l'aromatase des androgènes dans ce même tissu. Une femme ménopausée ayant un IMC > 30 est considérée comme présentant un surrisque de 31 % de développer un cancer du sein.[53]

### **B. Activité physique**


L'exercice physique régulier est un facteur de protection prouvé pour prévenir les risques Cancer du sein. En termes d'intensité, une activité vigoureuse semble être plus rentable que les activités de faible intensité. En général pour limiter le risque de cancer, une activité physique de haute intensité est recommandée Modéré à sévère pendant au moins 30 minutes. Plusieurs mécanismes biologiques ont été proposés pour expliquer ses effets protecteurs de l'activité physique, tenant compte des changements entre les deux métabolismes, hormones et immunité.

### **C. Cigarette**

est un facteur de risque du cancer du sein qui reste controversé. Les études portant sur ce sujet ayant retrouvé des résultats contradictoires.

## D. Alcool

Une consommation régulière d'alcool est associée à une augmentation du risque de développer un cancer du sein. L'alcool serait susceptible de faire augmenter les taux d'œstradiols circulants.



**Figure 43:** Un diagramme schématisé des facteurs de risque est représenté dans une structure.[47]

## IV.7 Dépistage du cancer du sein

Le dépistage consiste à détecter le cancer avant qu'il ne soit palpable ou qu'il ne montre des signes d'anomalie, comme des changements au niveau de la peau ou des mamelons. Dépister précocement certains cancers permet de mieux le soigner en proposant des traitements moins lourds, offrant ainsi de meilleures chances de guérison.

Le but du **dépistage** est de « trouver les anomalies qui montrent le potentiel de devenir cancéreuses ou de se développer en cancer chez les personnes qui n'ont pas été touchées par la maladie auparavant afin qu'elles puissent être traitées rapidement ».

Le test utilisé pour détecter le cancer du sein est une « mammographie ». Les mammographies peuvent détecter de petites anomalies, dont seulement certaines se transformeront en cancer. Ces anomalies sont parfois détectées même lorsque l'examen clinique est anormal. Si des anomalies sont détectées, le médecin peut prescrire des tests supplémentaires (mammographies supplémentaires, échographies, aiguilles et éventuellement une biopsie) pour confirmer ou infirmer le diagnostic de cancer.

Le dépistage doit concerner toutes les femmes, notamment après la ménopause ; il fait appel à :

- La palpation mammaire annuelle systématique au cours des consultations chez le médecin traitant ou le gynécologue.

- La mammographie bilatérale tous les deux ans après 45 ans, voire plutôt et à un rythme annuel chez les femmes à risque (cliché simple médiolatéral oblique : méthode de tabar, ou plutôt deux clichés). Ne pas omettre de dire aux femmes d'apporter leurs mammographies antérieures, l'interprétation de certaines images n'étant possible qu'en fonction de leur évolutivité.

- L'autopalpation : de façon schématique, les signes en faveur de la malignité à la mammographie sont une opacité dense spiculée, avec un halo clair et la présence de microcalcifications fines et groupées. L'interprétation des clichés demande toutefois une grande expérience. Le dépistage au moyen de campagnes de masse a prouvé son efficacité et devrait permettre un gain de l'ordre de 25 à 30 % sur la mortalité. Ces campagnes sont organisées par les Caisses primaires d'assurance maladie de chaque département.

#### **IV.8 Les symptômes du cancer du sein**

Il existe différents stades du cancer du sein, qui sont déterminés en fonction de la taille de la tumeur, de la présence de cellules cancéreuses dans les ganglions lymphatiques et de la présence de métastases. Les stades du cancer du sein sont classés de 0 à IV :

- **Stade 0** : également appelé carcinome in situ, il s'agit d'une tumeur non invasive qui est confinée à la glande mammaire. Ce stade est souvent détecté à travers une mammographie de dépistage.

- **Stade I** : la tumeur est petite (moins de 2 cm) et n'a pas envahi les ganglions lymphatiques ni d'autres parties du corps.

- **Stade II** : la tumeur mesure entre 2 et 5 cm, et il peut y avoir une propagation des cellules cancéreuses aux ganglions lymphatiques de l'aisselle (nœuds lymphatiques axillaires).

- **Stade III** : le cancer a envahi les ganglions lymphatiques de l'aisselle et/ou du cou, et peut également affecter la peau et les tissus environnants du sein.

- **Stade IV** : également appelé cancer métastatique, le cancer s'est propagé à d'autres parties du corps, comme les os, le foie, les poumons ou le cerveau.

Il est important de souligner que chaque cas de cancer du sein est unique et peut présenter des caractéristiques différentes. Le stade de la maladie est l'un des éléments importants qui permettent de déterminer le traitement le plus approprié pour chaque patiente

[51]

## **IV.9 Diagnostic du cancer du sein**

### **IV.9.1 L'examen clinique**

c'est un examen réalisé avant et après la mammographie pour mettre en évidence d'éventuelles anomalies des certaines régions et expliquer certains résultats, ainsi une corrélation entre clinique et imagerie est réalisée

### **IV.9.2 Mammographie**

L'examen incontournable de l'exploration de la glande mammaire et peut être compléter par une échographie mammaire.

### **IV.9.3 L'échographie mammaire**

Il donne des informations précises sur le type de cancer du sein. Bienfait à l'analyse au microscope des cellules et des tissus enlevés au niveau d'une anomalie du sein.

### **IV.9.4 Le scanner**

C'est un test qui ne permet pas le diagnostic du cancer du sein à lui seul, mais c'est la conséquence du cancer du sein qui permet la recherche de métastases.

### **IV.9.5 IRM (Imagerie par Résonance Magnétique)**

Plus rarement, et lorsqu'il n'y a pas d'anomalie pendant la période d'incertitude. Dans les deux examens précédents, l'imagerie par résonance magnétique (IRM) du sein peut fournir. En particulier, l'IRM peut être utilisée pour distinguer les anomalies bénignes des anomalies malignes. Lors de la planification d'une chimiothérapie néoadjuvante, l'IRM mammaire est également utilisée Évaluer la réponse clinique après le traitement et avant la chirurgie.

### **IV.9.6 La biopsie**

Nous avons vu auparavant, la plupart des techniques de diagnostic du cancer du sein ne suffisent pas à elles seules à confirmer l'état de la tumeur Exister, Le radiologue n'est pas sûr L'interprétation de l'image nécessite une biopsie. C'est ce qui confirmera ou infirmera l'hypothèse d'un cancer du sein. Il existe plusieurs types de biopsies, et le type de biopsie réalisée à chaque fois dépendra du patient. En termes d'état clinique de la tumeur et du patient. Le but est d'observer la lésion au microscope à chaque fois.[48]

## IV.10 Traitement

Le but du traitement du cancer du sein :

### A. Local

- Guérir
- Eviter les récurrences
- Eviter les séquelles

### B. Evolué

- Améliorer la qualité de vie
- Prolonger la survie

## IV.10.2 Chirurgie

### a. La chirurgie tumorale

Son but est d'obtenir une résection complète de la tumeur avec des marges saines afin de réduire les risques de rechute. Deux types de chirurgie peuvent être proposés en fonction de la taille tumorale, de la multi-focalité de la tumeur, présence ou absence d'une contre-indication ou encore du choix de la patiente.

- La chirurgie non conservatrice (mastectomie).
- La chirurgie conservatrice (tumorectomie ou encore mastectomie partielle).




Figure 44 : Les types de chirurgies dans le cancer du sein.[52]

## b. La chirurgie ganglionnaire

### •Le curage ganglionnaire axillaire

Les ganglions qui se trouvent sous le bras au niveau de l'aisselle sont les principaux qui peuvent être atteints par le cancer du sein, ils sont nommés ganglions axillaires. Malgré son avantage dans la détection de la présence de cellules cancéreuses, il entraîne parfois un lymphœdème.

### •La technique du ganglion sentinelle

La technique du ganglion sentinelle, permet d'éviter les curages axillaires inutiles et ses conséquences (risque de lymphœdème) [50]




Figure 45: La technique du ganglion sentinelle [52]

## IV.10.3 Radiothérapie

Le principe de la radiothérapie repose sur un traitement locorégional. Trois types de radiothérapie existent :

- La radiothérapie externe
- La curiethérapie ou radiothérapie interne
- La radiothérapie peropératoire.

## IV.10.4 Traitement systémique

### a. Objectifs

- En situation adjuvante (après un geste carcinologique, améliore la survie globale, élimine les micro-métastases) ;
- En situation néoadjuvante (avant le geste carcinologique) ;

- En situation métastatique.[50]

### **A. Chimiothérapie**

C'est un traitement systémique passant par la circulation sanguine ayant un impact sur les cellules à division rapide mais aussi les cellules saines entraînant par conséquent des toxicités.

En fonction des situations, la chimiothérapie peut être indiquée avant un traitement locorégional (néoadjuvante) ou après le traitement chirurgical on parle alors d'une chimiothérapie adjuvante. Souvent, les protocoles de chimiothérapie associent différents types de molécules anti-cancéreuses afin d'avoir une meilleure efficacité.

La chimiothérapie adjuvante administrée en postopératoire permet de réduire de 5 %.

### **B. Hormonothérapie**

Proposer aux patientes porteuses d'un cancer du sein qui expriment les récepteurs hormonaux. L'effet rechercher c'est l'effet anti-œstrogéniques.

Le choix de l'hormonothérapie se fait selon statut ménopausique de la patiente.

Castration : se fait par, la chirurgie, Radiothérapie, Les analogues de la LH-RH [51]

### **C. Thérapie ciblée**

Les thérapies ciblées entraînent un blocage de la croissance cellulaire, une inhibition de l'angiogenèse, ou de l'apoptose, divisées en deux grandes classes ; les anticorps monoclonaux et les inhibiteurs de tyrosine kinases.

#### **IV.10.5 Traitement non systémique**

C'est un traitement symptomatique complémentaire destiné à prévenir ou réduire les effets secondaires causés par la chimiothérapie. [50]



### **Conclusion**

Le cancer du sein est une maladie grave qui survient chez les jeunes patientes. Ce travail sur le cancer du sein permet aux jeunes femmes de faire la distinction entre diverses épidémies, maladies cliniques et anatomiques et traitements, caractéristiques progressives et prédictives. Il existe des renseignements utiles sur les facteurs de risque et les paramètres des facteurs tissulaires liés au développement du cancer du sein, comme l'âge (40 ans ou moins), le sexe (femme), les antécédents personnels, hormonaux et familiaux, la ménopause, l'allaitement, l'état matrimonial et la profession. Une prise en charge multidisciplinaire est donc nécessaire, un diagnostic précoce de la maladie, encourageant les femmes à risque à consulter en génétique du cancer et développer des thérapies adaptées au pronostic des jeunes femmes pour améliorer le diagnostic. Il serait intéressant de revoir ses indicateurs, surtout compte tenu de l'augmentation du cancer chez les jeunes femmes et du mauvais diagnostic. Nous devons donc poursuivre nos efforts dans le domaine de la détection et de la prévention.

***Chapitre V :***  
***Implémentation et discussion des résultats***

## V.1 Introduction

Après avoir présenté, les concepts généraux de traitement d'image et d'ordinateur Vision en particulier la classification des images et les techniques d'apprentissage profond et l'apprentissage à profond, ce chapitre est consacré à présenter les outils et les bibliothèques utilisés dans nos expériences.

Ensuite, nous détaillons la mise en œuvre du modèle VGG-16, VGG-19, MobileNet, DenseNet en Plate-forme Colab sur l'ensemble de données MIAS ainsi que le modèle KNN, résultats obtenus et comparaison entre CNN et KNN.

## V.2 Outils et bibliothèques

### V.2.1 Python : python™

Python est le langage de programmation open source le plus utilisé dans le domaine de l'intelligence artificielle et surtout en Deep Learning vu qu'il contient un nombre important de bibliothèques performantes et utiles pour la vision artificielle et l'utilisation des réseaux de neurones. Il est conçu pour optimiser la productivité des programmeurs en orant des outils de haut niveau et une syntaxe simple à utiliser Depuis quelques années. Notre projet est fait avec le langage de Python dans le cloud et on n'aura pas besoin d'installer un logiciel ou un IDE dans notre ordinateur [54].

- **TensorFlow** 

TensorFlow est une plate-forme open source de bout en bout pour l'apprentissage automatique. Il a un écosystème d'outils, de bibliothèques et de ressources communautaires les chercheurs poussent l'état de l'art en ML et les développeurs facilement construire et déployer ML applications motorisées.[55]

- **Keras** 

Keras est une API d'apprentissage profond écrite en Python, fonctionnant sur la machine plate-forme d'apprentissage TensorFlow. Il a été développé en mettant l'accent sur

l'expérimentation. Être capable de passer d'une idée à un résultat aussi rapidement que possible est la clé pour faire le bien recherche.[56]

• **OpenCV** 

OpenCV (Open Source Computer Vision Library) est une vision informatique open source et bibliothèque de logiciels d'apprentissage automatique. OpenCV a été construit pour fournir un pour les applications de vision par ordinateur et pour accélérer l'utilisation des perceptions dans les produits commerciaux. Étant un produit sous licence BSD, OpenCV rend facile pour que les entreprises utilisent et modifient le code. La bibliothèque a plus de 2500 algorithmes optimisés, qui comprend un ensemble complet de vision et d'apprentissage automatique classiques et de pointe algorithmes. Ces algorithmes peuvent être utilisés pour détecter et reconnaître les visages, identifier les objets, classer les actions humaines en vidéos, suivre les mouvements des caméras, suivre les objets en mouvement, extraire 3D modèles d'objets, produire des nuages de points 3D à partir de caméras stéréo, assembler des images produire une image haute résolution d'une scène entière, trouver des images similaires à partir d'une image base de données, supprimer les yeux rouges des images prises à l'aide de flash, suivre les mouvements des yeux, reconnaître paysage et établir des marqueurs pour le superposer avec la réalité augmentée, etc. OpenCV a plus plus de 47 mille personnes de la communauté des utilisateurs et le nombre estimé de téléchargements dépassant 18 millions. La bibliothèque est largement utilisée dans les entreprises, les groupes de recherche et par organismes gouvernementaux.[57]

• **Matplotlib** 

Matplotlib est une Bibliothèque complète pour créer des visualisations statiques, animées et interactives en Python

• **Pandas** 

Pandas est une autre bibliothèque Python utilisée pour la manipulation et l'analyse des données, le point fort de cette bibliothèque est qu'elle possède une fonctionnalité importante appelée nettoyage des données qui résout le problème du temps passé à nettoyer les données dans un projet d'apprentissage automatique car de nombreux ensembles de données

disponibles contiennent des champs vides ou nuls, ce qui peut avoir un impact négatif énorme sur notre modèle.[58]

- NumPy



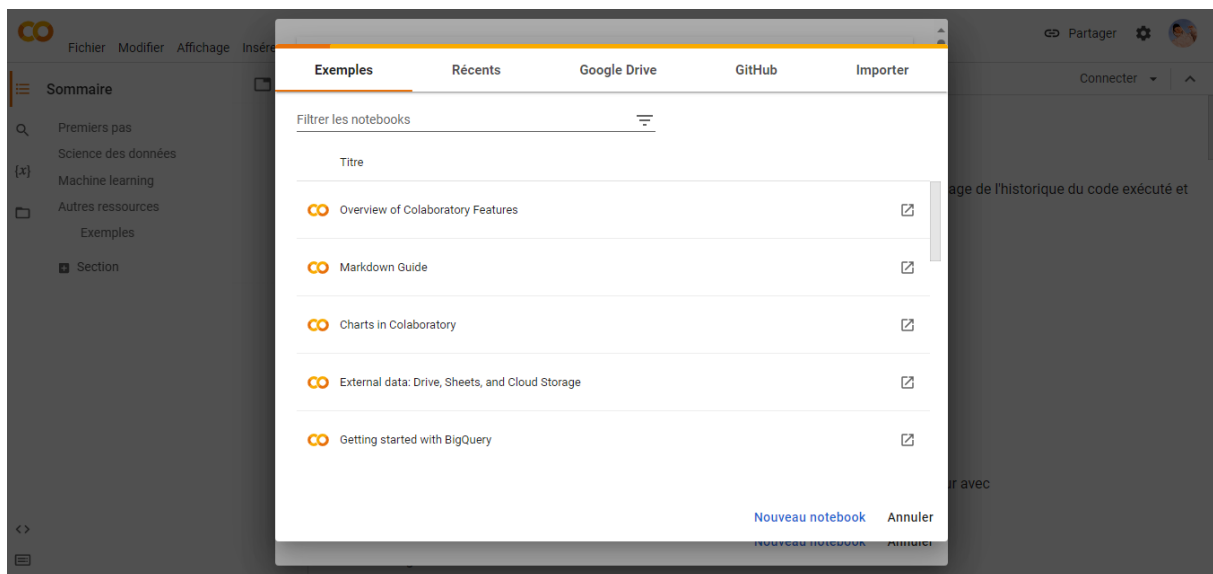
NumPy est une extension du langage de programmation Python, destinée à manipuler des tableaux multidimensionnels.

## V.2.2 Google Colab :



Colaboratoire, ou « Colab », est un produit de Google Research. Colab permet n'importe qui pour écrire et exécuter du code python arbitraire par le navigateur, et est surtout l'apprentissage automatique, l'analyse des données et l'éducation. Plus techniquement, Colab est un service de portable Jupyter hébergé qui ne nécessite aucune configuration à utiliser, tout en fournissant un accès gratuit à ressources informatiques, y compris les GPU.[59]

Suivre le lien <https://colab.research.google.com/> et se connecter avec le compte Gmail.



**Figure 46 :** Google Colab

### A. Avantages de Colab :

En plus d'être facile à utiliser, le Colab est assez flexible dans sa configuration et fait beaucoup de travail pour nous :

- Prise en charge de Python 2.7 et Python 3.6
- Accélération GPU gratuite
- Bibliothèques préinstallées : les principales bibliothèques de Python comme TensorFlow, Scikit-learn, entre autres, sont préinstallées et prêtes à être importées.
- Prend en charge les commandes Bash (langage de commande).[59]

### V.2.3 Navigateur Anaconda

Anaconda Navigator est une interface utilisateur graphique de bureau (GUI) incluse dans Distribution Anaconda qui vous permet de lancer des applications et de gérer facilement conda paquets, environnements et canaux sans utiliser de commandes en ligne de commande. Navigateur peut rechercher des paquets sur Anaconda Cloud ou dans un dépôt Anaconda local. Il est disponible pour Windows, macOS et Linux.[60]

### V.2.4 Jupyter Notebook

Le Jupyter Notebook est une application web open-source qui permet de créer et partager des documents qui contiennent du code réel, des équations, des visualisations et du texte narratif. Utilisations : nettoyage et transformation des données, simulation numérique, modélisation statistique, visualisation des données, apprentissage automatique et bien plus encore.[61]

### V.2.5 Google drive :

- Pour monter le drive dans le dossier « gdrive », on exécute la commande :

```
from google.colab import drive
```

```
drive.mount('/content/gdrive')
```




Figure 47 : comment utiliser drive.

### **V.3 Description de la base MIAS :**

<https://www.kaggle.com/datasets/kmader/mias-mammography>

L'ensemble de données MIAS est un ensemble de mammographies numériques, qui sont des mammographies. Il a été créé pour faciliter la recherche et le développement de systèmes de diagnostic assisté par ordinateur (CAD) pour la détection et le diagnostic du cancer du sein. L'ensemble de données contient un total de 322 images, chacune stockée sous forme de fichier bitmap avec un seul canal 24 bits avec une résolution de 1024x1024 pixels, fourni dans les enregistrements :


- Dossier 1 : Avoir une tumeur avec 114 images.
- Dossier 2 : Il n'y a pas de tumeur avec 208 images.

En plus des images, le jeu de données comprend également des explications pour certaines photos. Les annotations fournissent des informations sur l'existence d'anomalies dans les mammographies, telles que les blocs, les microcalogrammes et les anomalies architecturales. L'ensemble de données comprend également des renseignements sur la gravité de l'anomalie, si possible.

Les chercheurs et les praticiens en apprentissage automatique peuvent utiliser cet ensemble de données pour développer et évaluer des algorithmes de détection et de classification automatiques des anomalies mammaires. Il a été largement utilisé dans le domaine de l'imagerie médicale et a contribué aux progrès dans les systèmes de diagnostic assisté par ordinateur pour le cancer du sein.

Pour mettre en œuvre ce projet de dépistage du cancer du sein, il a fallu créer une base de données contenant des images de tumeurs. Nos données proviennent de la plateforme open source "kaggle/dataset '2.

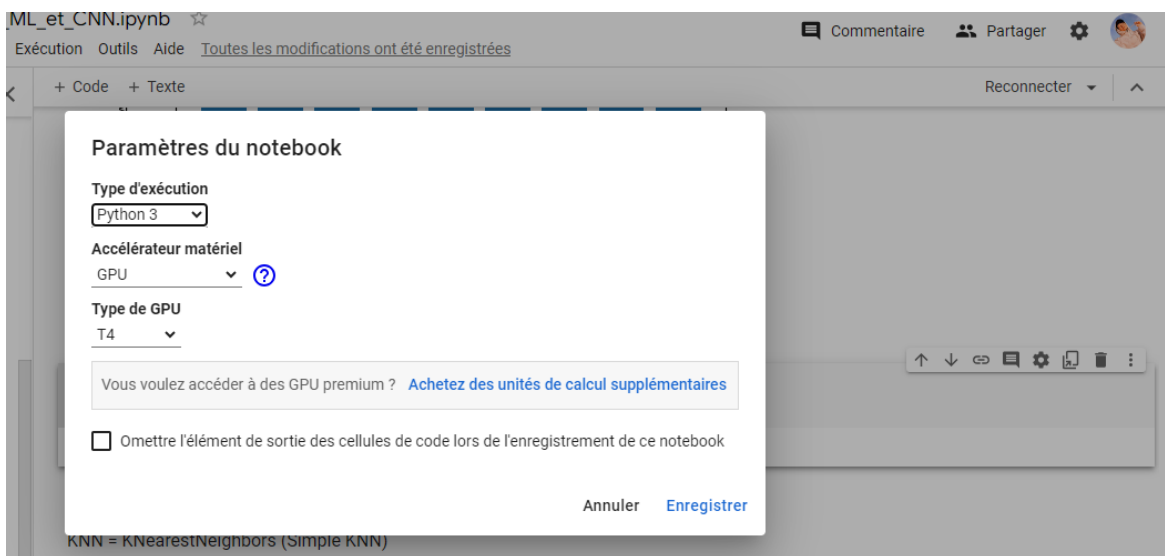
La technologie de traitement d'images a été utilisée pour créer plus de données/images pour les données originales afin de résoudre les images de cancer perdues parce qu'elles sont très rares sous la forme de nos réseaux neuronaux. Cette technique est appelée "données améliorées", et sera expliquée plus tard dans ce chapitre.[62]



**Figure 48** : représente les classes de l'ensemble de données.

- **Choisir l'accélérateur matériel**

Dans la barre des options choisir "exécution"(Runtime) puis "modifier le type d'exécution" (Change Runtime Type) et mettre l'option accélérateur matériel (Hardware Accelerator) en mode GPU ou TPU (Tensor Processing Unit). bien expliquer dans ces figures suivantes :



**Figure 49** : choisir l'accélération matériel



- Importer les bibliothèques Python

```
import os
import sys
# path manipulation
from pathlib import Path
# regex
import re
# plotting
import matplotlib.pyplot as plt
import matplotlib.image as mpimg
from matplotlib.patches import Circle
# data manipulation / preparation
import numpy as np
import pandas as pd
import h5py
from sklearn.model_selection import train_test_split
from tensorflow.keras.preprocessing.image import ImageDataGenerator
# image manipulation
from PIL import Image
from IPython.display import Image
from sklearn.metrics import confusion_matrix, classification_report
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Conv2D, Dense, Flatten, MaxPool2D, Dropout
from tensorflow.keras.utils import plot_model
```

Figure 50: Importer les bibliothèques utilisées.

- Importer la base de données

```
import opendatasets as od
import pandas
od.download("https://www.kaggle.com/datasets/kmader/mias-mammography")
```

```
Downloading mias-mammography.zip to ./mias-mammography
100%|██████████| 312M/312M [00:15<00:00, 21.1MB/s]
```

Figure 51 : installé le dataset (MIAS)

- Diviser les données en données d'apprentissage et de testes

```
X_train = data_gen.flow_from_dataframe(X,x_col="subsample_path",y_col="severity",
X_val = data_gen.flow_from_dataframe(X,x_col="subsample_path",y_col="severity",c
y_val = data_gen.flow_from_dataframe(y,x_col="subsample_path",y_col="severity",c
y_test = data_gen.flow_from_dataframe(y,x_col="subsample_path",y_col="severity",
```

```
Found 208 validated image filenames belonging to 2 classes.
Found 52 validated image filenames belonging to 2 classes.
Found 23 validated image filenames belonging to 2 classes.
Found 5 validated image filenames belonging to 2 classes.
```

Figure 52: Code de Division des données apprentissage/testes

### • Augmentation d'images (Data Augmentation)

C'est une technique appliquée à des données d'entraînement existantes pour créer artificiellement de nouvelles données d'entraînement. Les techniques d'augmentation peuvent créer des variations des images qui peuvent améliorer la capacité des modèles à généraliser ce qu'ils ont appris à de nouvelles images telle que les nouvelles images à partir à la même classe que les images originales. Il existe plusieurs types d'augmentation des données, on a proposé quelques-unes, ils sont résumés dans la figure suivante :

On a utilisé la technique de rotation pour l'augmentation des données automatiquement à l'aide de la bibliothèque de Deep Learning « Keras » par la classe `ImageDataGenerator`.

## V.4 Le modèle CNN (deep learning) :

### V.4.1 Implémentation du modèle CNN

On va utiliser les modèles CNN (VGG-16, VGG-19, MobileNet2, DenseNet) pour classifier les images de cancer du sein.

```
from tensorflow.keras.applications.vgg16 import VGG16
from tensorflow.keras.applications.vgg19 import VGG19
from tensorflow.keras.applications.mobilenet_v2 import MobileNetV2
from tensorflow.keras.applications.densenet import DenseNet121
model16 = VGG16()
model19 = VGG19()
modelDN = DenseNet121()
modelMNV2 = MobileNetV2()
#model16.summary()
```

Figure 53 : Code de préparation importes les modèles CNN

### • Construction des modèles VGG-16, VGG19, MobileNet, DenseNet

```
[ ] model_16 = VGG16(weights = "imagenet", include_top=False, input_shape=(256,256,3))
model_16.trainable = False
flat1 = Flatten()(model_16.layers[-1].output)
class1 = Dense(512, activation="relu")(flat1)
#class2 = Dense(50, activation="relu")(class1)
#class3 = Dense(1024, activation="relu")(class2)
output = Dense(2, activation="softmax")(class1)
model_16 = Model(inputs=model_16.inputs, outputs=output)
```

Figure 54 : Construction de modèle VGG-16

```

model_19 = VGG19(weights = "imagenet", include_top=False, input_shape=(256,256,3))
model_19.trainable = False
flat19 = Flatten()(model_19.layers[-1].output)
class19 = Dense(512, activation="relu")(flat19)
#class2 = Dense(50, activation="relu")(class1)
#class3 = Dense(1024, activation="relu")(class2)
output19 = Dense(2, activation="softmax")(class19)
model_19 = Model(inputs=model_19.inputs, outputs=output19)

```

*Figure 55* : Construction de modèle VGG-19

```

modelMNV2 = MobileNetV2(weights = "imagenet", include_top=False, input_shape=(256,256,3))
modelMNV2.trainable = False
flatMNV2 = Flatten()(modelMNV2.layers[-1].output)
classMNV2 = Dense(512, activation="relu")(flatMNV2)
#class2 = Dense(50, activation="relu")(class1)
#class3 = Dense(1024, activation="relu")(class2)
outputMNV2 = Dense(2, activation="softmax")(classMNV2)
modelMNV2 = Model(inputs=modelMNV2.inputs, outputs=outputMNV2)

```

*Figure 56*: Construction de modèle MobileNet

```

[ ] modelDN = DenseNet121(weights = "imagenet", include_top=False, input_shape=(256,256,3))
modelDN.trainable = False
flatDN = Flatten()(modelDN.layers[-1].output)
classDN = Dense(512, activation="relu")(flatDN)
#class2 = Dense(50, activation="relu")(class1)
#class3 = Dense(1024, activation="relu")(class2)
outputDN = Dense(2, activation="softmax")(classDN)
modelDN = Model(inputs=modelDN.inputs, outputs=outputDN)

```

*Figure 57* : Construction de modèle DenseNet

### • compilation des modèles VGG-16, VGG19, MobileNet, DenseNet

```

metrics=['accuracy',
tf.keras.metrics.Precision(),
tf.keras.metrics.Recall(),
tf.keras.metrics.AUC(),
tf.keras.metrics.TruePositives(),
tf.keras.metrics.TrueNegatives(),
tf.keras.metrics.FalsePositives(),
tf.keras.metrics.FalseNegatives(),
tf.keras.metrics.SensitivityAtSpecificity(0.5),
tf.keras.metrics.SpecifictyAtSensitivity(0.5)]

model_16.compile(optimizer=adam_opt, loss=model_loss, metrics=metrics)
model_19.compile(optimizer=adam_opt, loss=model_loss, metrics=metrics)
modelMNV2.compile(optimizer=adam_opt, loss=model_loss, metrics=metrics)
modelDN.compile(optimizer=adam_opt, loss=model_loss, metrics=metrics)

```

*Figure 58* : compilation des modèles de CNN.

- **Transfert d'apprentissage**

Le modèle est utilisé avec beaucoup de paramètres mais la majorité est réglé initialement en utilisant le transfert d'apprentissage :

```
-----
Total params: 31,493,442
Trainable params: 16,778,754
Non-trainable params: 14,714,688
```

- **Affiche de résultats d'évaluation de la classification**

```
▶ start_time = time.time()
history_16 = model_16.fit(X_train, validation_data=X_val, epochs=50, callbacks=[early_stopping, model_check_point_16])
end_time = time.time()
print("Training time for VGG16: ", end_time - start_time, "secs")
```

*Figure 59* : Code d'affichage des résultats (précision, accuracy, racall, Auc, loss).

```
[ ]
results_plot = plot_results(history_16.history['accuracy'],
                             history_16.history['val_accuracy'],
                             history_16.history['loss'],
                             history_16.history['val_loss'])

# enter data to the final results dataframe
results_calc = classification_report(expected16, predicted16, output_dict=True)
```


*Figure 60*: Code des tracés des courbes de modèle (précision et perte).

## V.4.2 Résultats de modèle CNN

Résultats de construction et compilation des modèles donnés sous forme de son architecture et ses paramètres.

**A. VGG-16 :**


• **Evaluation du modèle**



**Figure 61 :** La courbe de perte (loss) et la courbe de précision (accuracy) de réseau VGG-16.

**B. VGG-19 :**


• **Evaluation du modèle**



**Figure 62 :** La courbe de perte (loss) et la courbe de précision (accuracy) de réseau VGG-19.

**C. MobileNet :**

• **Evaluation du modèle**




*Figure 63 : La courbe de perte (loss) et la courbe de précision (accuracy) de réseau MonileNet*

➤ Nous remarquons que la précision du modèle DenseNet est le rapport le plus élevé qui augmente et se stabilise lorsque une valeur proche de 0,98, qui est un bon résultat de nos données puis suivie de la précision du modèle MobileNet est également proche de 0,98, après ce modèle VGG-19 résolution approchant 0,86 .

➤ Enfin, la précision du modèle VGG-16 est la plus faible proportion de modèles CNN.

**D. DenseNet :**

• **Evaluation du modèle**



*Figure 64 : La courbe de perte (loss) et la courbe de précision (accuracy) de réseau DenseNet.*

### V.4.3 Comparaison entre les 04 modèles (VGG-16, VGG-19, MobileNet, DenseNet)

On a fait cette comparaison en termes de précision du modèle, temps d'exécution entre les modèles 04 de CNN.

- **précision des modèles CNN :**




Figure 65 : L'histogramme de la Comparaison entre les différents modèles de CNN.

➤ Nous remarquons que la précision de le modèle DenseNet et MobileNet est supérieure à Précision de le modèle VGG-19 et VGG-16.

- **temps d'exécution des modèles :**

```

1/1 [=====] - 5s 5s/step
1/1 [=====] - 1s 565ms/step
1/1 [=====] - 2s 2s/step
1/1 [=====] - 4s 4s/step
Test time for VGG16: 5.049218416213989 secs
Test time for VGG19: 1.0415799617767334 secs
Test time for MNV2: 2.1402297019958496 secs
Test time for DN: 4.755953311920166 secs
    
```

Figure 66 : la Comparaison entre les différents temps d'exécution modèles de CNN.

- **Tableau de comparaison des résultats**

CNN Modèles	Accuracy	Loss	Temps d'exécution	Précision	Recall	Auc
VGG-16	0.83	0.45	1s	0.86	0.86	0.94
VGG-19	0.86	0.22	0s	0.91	0.91	0.97
MobileNet	0.98	0.20	0s	0.98	0.98	0.99
DenseNet	0.98	0.02	2s	0.98	0.98	0.99

*Tableau 5 : Tableau de comparaison des résultats de modèle CNN*

## V.5 Les modèles de machine learning :

Algorithmes et résultat : Dans la partie Machine learning nous avons utilisé 05 Algorithmes qui sont :

- ✓ **Algorithmes 01** : k plus proche voisins
- ✓ **Algorithmes 02** : Random Forest
- ✓ **Algorithmes 03** : DummyClassifier
- ✓ **Algorithmes 04** : Tpotclassifier
- ✓ **Algorithmes 05** : XGBClassifier

### V.5.1 k plus proche voisins

Dans la bibliothèque « sklearn » on appelle la fonction

```
from sklearn.neighbors import KNeighborsClassifier
```



	Précision	Recall	F1-Score	Support
Not depressed	<b>0.56</b>	<b>0.13</b>	<b>0.11</b>	<b>165</b>
depressed	<b>0.54</b>	<b>0.56</b>	<b>0.46</b>	<b>165</b>
			<b>Accuracy</b>	<b>56 %</b>

**Tableau 6 : Résultat obtenue avec KNN**

Le tableau précédent montre la performance de l'algorithme KNN à partir des données de test

### V.5.2 Random Forest

Dans la bibliothèque « sklearn » on appelle la fonction

```
from sklearn.ensemble import RandomForestClassifier
```

	Précision	Recall	F1-Score	Support
Not depressed	<b>0.63</b>	<b>0.17</b>	<b>0.16</b>	<b>165</b>
depressed	<b>0.62</b>	<b>0.63</b>	<b>0.51</b>	<b>165</b>
			<b>Accuracy</b>	<b>63 %</b>

**Tableau 7: Résultat obtenu avec NB**

Le tableau précédent montre la performance de l'algorithme NB à partir des données de test

V.5.3 DummyClassifier

	Précision	Recall	F1-Score	Support
Not depressed	0.62	0.14	0.11	165
depressed	0.61	0.62	0.48	165
			Accuracy	62 %

Tableau 8: Résultat obtenu avec DC

Le tableau précédent montre la performance de l’algorithme DC à partir des données de test

- Confusion Matrix

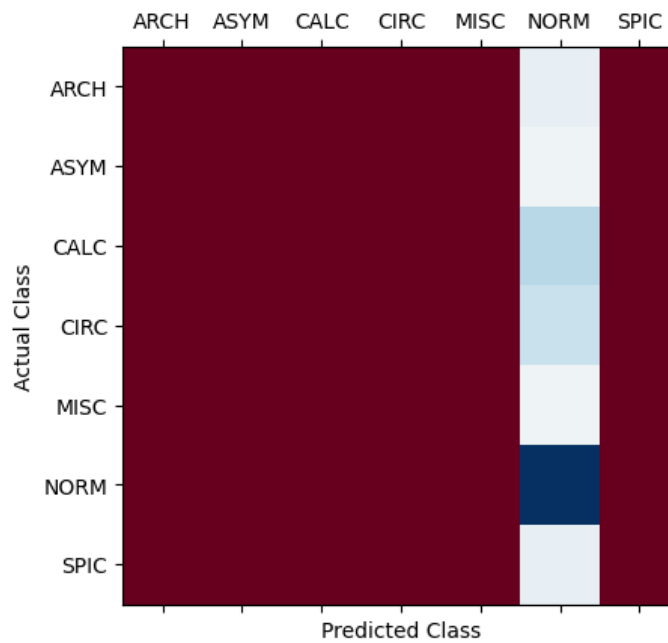



Figure 67: Confusion Matrix de modèle KNN

## V.6 La comparaison des algorithmes K plus proches voisins (KNN) et des modèles CNN (VGG-16, VGG-19, DenseNet et MobileNet) en mammographie.



*Figure 68 : L'histogramme de la Comparaison entre les différents modèles de CNN et les modèles de machine learning*

L'algorithme KNN a une précision de 58% en mammographie. Cela signifie qu'il est capable de prédire correctement la classe d'un échantillon de mammographie dans seulement 58 % des cas.

En revanche, les modèles CNN (VGG-16, VGG-19, DenseNet et MobileNet) ont des précisions nettement plus élevées en mammographie. VGG-16 atteint une précision de 83 %, VGG-19 atteint 86 %, DenseNet atteint 98 % et MobileNet atteint également 98 %.

Ces résultats indiquent que les modèles CNN sont beaucoup plus performants que l'algorithme KNN pour la tâche de classification des mammographies. Les modèles CNN, en particulier DenseNet et MobileNet, atteignent une précision exceptionnellement élevée de 98 %, ce qui suggère qu'ils sont capables d'identifier avec précision les caractéristiques spécifiques aux images de mammographie et de prédire efficacement les résultats.

## **Conclusion**

Dans ce chapitre, nous avons fourni une plate-forme pour faire "google colab" et le langage de programmation "Python" avec certaines de ses bibliothèques "OpenCV, Keras'... On a remarqué ça. L'environnement google colab est complet et très utile, il nous permet de mettre en œuvre tous nos codes en fournissant de très bons logiciels de ressources matérielles qui nous permettent de réaliser que nos applications sont de très bonnes conditions. Il nous fournit également des accélérateurs de matériaux (CPU/GPU/TPU) qui nous encouragent également à effectuer un apprentissage plus gourmand en termes d'exécution.

Ensuite, nous avons appliqué les modèles préférés de CNN. (Modèles d'apprentissage profond) sont (VGG-16, VGG-19, MobileNet, DenseNet) pour classer les mammographies dans les images de santé et de patient. Nous avons déjà pris des mesures. Dans la littérature, certains blogs exploiter les données existantes "kaggle." Nous avons vu comment traiter les photos au préalable, construire et assembler le modèle et appliquer le transfert d'apprentissage. et l'évaluation des modèles. Nous avons conclu que le modèle DenseNet et MobileNet pouvait classer nos données à environ 98 % et VGG-16, VGG-19 à environ 86 %. 83 %.

En fin de compte, nous avons fait une comparaison de performance entre les modèles 04 de CNN et conclu que MobileNet a la plus grande précision dans les modèles CNN, puis VGG-16, VGG-19.

Nous avons ensuite appliqué les modèles préférés de modèles d'apprentissage automatique (KNN, RFC, TPC, DC) pour classer les mammographies dans les images de santé et de patient. Nous avons conclu que le modèle PTC, DC, RFC pourrait classer nos données à environ 62 %, 62 %, 63 % et (KNN, XGBC) est d'environ 58 % , 56 %.

En fin de compte, nous avons comparé les performances entre les modèles 05 de modèles d'apprentissage automatique et conclu que le TPC a la plus grande précision dans les modèles d'apprentissage automatique.

Enfin, nous avons comparé le Deep Learning (CNN) avec le KNN pour classer les images mammographiques dans les images de santé et de patient, et nous avons appris que le Deep Learning (CNN) est meilleur que le KNN en termes de précision dans la prédiction du cancer du sein.

## **Conclusion Générale**

Le cancer du sein est l'un des types de cancer les plus courants chez les femmes dans le monde. Il est caractérisé par la croissance anormale des cellules mammaires qui peuvent se propager à d'autres parties du corps. Une détection précoce et précise du cancer du sein est nécessaire pour améliorer les chances de survie des patientes et faciliter leur traitement.

Au fil des ans, de nombreux progrès technologiques ont été réalisés dans la détection du cancer du sein. Parmi ces développements, les méthodes basées sur l'apprentissage automatique et l'apprentissage profond ont attiré une attention accrue. Deux algorithmes couramment utilisés dans la détection du cancer du sein sont les réseaux neuronaux artificiels (CNN) et les voisins les plus proches (KNN).

Une analyse comparative des CNN et des KNN dans le domaine de la mammographie révèle des résultats intéressants. Les CNN sont des modèles d'apprentissage en profondeur qui se sont avérés puissants pour extraire automatiquement les caractéristiques pertinentes des images de mammographie. Leur architecture profonde leur permet d'apprendre des représentations hiérarchiques, ce qui améliore leur capacité de classification.

D'autre part, KNN est une méthode d'apprentissage supervisé basée sur la proximité d'échantillons. Ils utilisent des méthodes de voisinage pour faire des prédictions. Les KNN ont montré une certaine efficacité dans certains cas, mais ils sont plus sensibles à la dimensionnalité des données et peuvent rencontrer des difficultés lorsque le nombre de variables ou de caractéristiques est important.

En comparant les performances de ces deux méthodes, on constate que CNN surpasse généralement KNN en termes de précision et de performances globales. La capacité des CNN à reconnaître des modèles complexes dans les images de mammographie leur donne un avantage pour détecter les anomalies et les premiers signes de cancer du sein.

Cependant, il convient de noter que les CNN nécessitent généralement des ensembles de données massifs et une puissance de calcul élevée pour la formation. De plus, l'interprétabilité des modèles CNN peut être un défi car leur fonctionnement est souvent considéré comme une "boîte noire". En conclusion, les CNN s'avèrent généralement plus efficaces et mieux adaptés à la classification des images mammographiques, bien que les KNN aient leur utilité dans certains cas particuliers. Leur capacité à extraire automatiquement des caractéristiques

## *Conclusion Générale*

---

significatives des données d'imagerie pourrait contribuer à améliorer la détection précoce du cancer du sein et ouvrir de nouvelles perspectives pour le développement de systèmes d'aide au diagnostic plus avancés dans le domaine de la mammographie.

## *Bibliographie*

- [1] LeCun, Y. (2017). Qu'est-ce que l'intelligence artificielle. chaire Recherches sur l'intelligence artificielle, informatique et sciences numériques (2015-2016), Collège de France, [https://www.college-de-france.fr/media/yannlecun/UPL4485925235409209505\\_Intelligence\\_Artificielle\\_\\_\\_\\_Y.\\_LeCun.pdf](https://www.college-de-france.fr/media/yannlecun/UPL4485925235409209505_Intelligence_Artificielle____Y._LeCun.pdf). visité le 5/02/2023
- [2] What is Machine Learning? <https://www.ibm.com/topics/machine-learning#toc-deep-learn-nOh7s5Rf> visité le 10/02/2023
- [3] Ray, S. (2019). Commonly used Machine Learning Algorithms. Analytics Vidhya. [analyticsvidhya.com/blog/2017/09/common-machine-learning-algorithms/](https://analyticsvidhya.com/blog/2017/09/common-machine-learning-algorithms/). Accessed, 17.
- [4] Reese, H. (2017). Understanding the differences between AI, machine learning, and deep learning. URL: <https://www.techrepublic.com/article/understandingthedifferencesbetweenaimachinelearninganddeeplearning.11/02/2023>
- [5] Heaton, J. (2018). Ian Goodfellow, Yoshua Bengio et Aaron Courville: Deep learning: The MIT Press, 2016, 800 pp, ISBN: 0262035618. Genetic Programming and Evolvable Machines, 19(1-2), 305-307.28/02/2023
- [6] Wang, H., & Raj, B. (2017). On the origin of deep learning. arXiv preprint arXiv:1702.07800.17/02/2023
- [7] Maaref, A. (2019). Prediction of Chemotherapy Response of Liver Metastases from Baseline CT-Images Using Deep Neural Networks (Doctoral dissertation, Ecole Polytechnique, Montreal (Canada)). 16/02/2023
- [8] Inaam, d. systeme de reconnaissance d'iris par reseaux de neurones convolutionnels (doctoral dissertation, university of kasdi merbah ouargla).
- [9] Mermillod, M. (2016). Réseaux de neurones biologiques et artificiels: vers l'émergence de systèmes artificiels conscients?. De Boeck Supérieur.22/02/2023
- [10] Gauthier, E. (1999). Utilisation des réseaux de neurones artificiels pour la commande d'un véhicule autonome (Doctoral dissertation, Institut National Polytechnique de Grenoble-INPG).

- [11] SEKKIL, H. M., & MEBROUKI, M. (2021). Etude comparative entre les différentes architectures des réseaux de neurones convolutifs (CNNs) pour la détection de la fatigue du conducteur (Doctoral dissertation, Directeur: Melle. Imane NEDAJR/Co-Directeur: M. MEGNAFI Hichem).25/02/2023
- [12] Fleet, D., Pajdla, T., Schiele, B., & Tuytelaars, T. (Eds.). (2014). Computer Vision--ECCV 2014: 13th European Conference, Zurich, Switzerland, September 6-12, 2014, Proceedings, Part I (Vol. 8689). Springer.
- [13] Zerzaihi, H., & Zarour, F. (2020). Reconnaissance d images par les réseaux de neurones convolutifs (Doctoral dissertation, University of Jijel).
- [14] Hakim, B., & Brahim, S. (2018). Classification des images avec les réseaux de neurones convolutionnels (Doctoral dissertation, Université Mouloud Mammeri).15/03/2023
- [15] Hubel, D. H., & Wiesel, T. N. (1959). Receptive fields of single neurones in the cat's striate cortex. *The Journal of physiology*, 148(3), 574. 23/03/2023
- [16] LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- [17] Ikechukwu, A. V., Murali, S., Deepu, R., & Shivamurthy, R. C. (2021). ResNet-50 vs VGG-19 vs entraînement à partir de zéro: Une analyse comparative de la segmentation et de la classification de la pneumonie à partir d'images radiographiques pulmonaires. *Global Transitions Proceedings*, 2(2), 375-381.
- [18] Jaworek-Korjakowska, J., Kleczek, P. et Gorgon, M. (2019). Prédiction de l'épaisseur du mélanome basée sur un réseau neuronal convolutif avec apprentissage par transfert de modèle VGG-19. Dans *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops* (pp. 0-0).
- [19] Chen, J., Wan, Z., Zhang, J., Li, W., Chen, Y., Li, Y., & Duan, Y. (2021). Medical image segmentation and reconstruction of prostate tumor based on 3D AlexNet. *Computer methods and programs in biomedicine*, 200, 105878..
- [20] Du, G., Cao, X., Liang, J., Chen, X., & Zhan, Y. (2020). Medical image segmentation based on u-net: A review. *Journal of Imaging Science and Technology*.29/03/2023



- [21] Jiechieu, F., & Tsopze, N. (2022). Une approche basée sur la méthode LRP pour l'explication des Réseaux de Neurones Convolutifs appliqués à la classification des textes.01/04/2023
- [22] S.-H. Tsang, « Review: YOLOv1 — You Only Look Once (Object Detection) », Medium, 20 mars 2019. <https://towardsdatascience.com/yolov1-you-only-look-once-object-detection-e1f3ffec8a89> 1/04/2023
- [23]Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). Imagenet classification with deep convolutional neural networks. Communications of the ACM, 60(6), 84-90.
- [24] T. M. Mitchell, "Machine learning, volume 1 of 1," 1997. Machine Learning - Tom Michael Mitchell - Google Livres
- [25] J. A. Nichols, H. W. Herbert Chan and M. A. B. Baker, "Machine learning: applications of artificial intelligence to imaging and diagnosis.," Biophysical reviews, vol. 11, no. 1, pp. 111-118, 2 2019.
- [26] Intelligence artificielle et apprentissage profond en pathologie Stanley Cohen 2020
- [27] <https://hal.science/inria-00494814/>. 16/04/2023
- [28] site web: <http://www.commentcamarche.net/contents/1216-traitement-d-images>. 19/04/2023
- [29] Bolon, P., Chassery, J. M., Cocquerez, J. P., Demigny, D., Graffigne, C., Montanvert, A., ... & Maître, H. (1995). Analyse d'images: filtrage et segmentation.
- [30] Djilali, Mr.Matmour. "Segmentation en ligne et en mots de texte des documents imprimés" . 2010-2011. PP:36-40.
- [31] A. Boucher, C. Garbay, "Des agents specialises pour la comprehension de sequences d'images ", RFIA. 98, vol.11, pp.275-284, 1998
- [32] Barki, F., Bouhali, R., & Laidi, K. (2013). Segmentation d'image couleure par les méthodes de seuillge.
- [33] Lefèvre, S. (2009, January). Une nouvelle approche pour la classification non supervisée en segmentation d'image. In EGC (pp. 127-138).

- [34] L.Lechlek, M .Ghougal.2012''la segmentation d'image médicale par la méthode d'ensemble de niveaux (level sets)'' .Thésede Master, Université Larbi Ben M'hidi Oum El Bouaghi. 25/04/2023
- [35] Krapac, J. (2011). Représentations d'images pour la recherche et la classification d'images (Doctoral dissertation, Caen).
- [36] Rousset, P. (1999). Applications des algorithmes d'auto-organisation à la classification et à la prévision (Doctoral dissertation, Paris 1).
- [37] Hoog-Labouret, N., & Merlet, F. (2013). Consequences of cancer treatments and fertility preservation: Report and propositions: État des connaissances et propositions Rapport de l'Institut national du cancer et de l'Agence de la biomédecine. *Oncologie*, 15, 263-270.
- [38] Wilson TE, Helvie MA, August DA. Breast cancer in the elderly patient: early detection with mammography. *Radiology*. 1994;190:203-7.
- [39] <https://cancer.ca/fr/cancer-information/cancer-types/breast/what-is-breast-cancer>. 29/04/2023
- [40] Miller AB, Baines CJ, To T, Wall C. Canadian National Breast Screening Study: 1. Breast cancer detection and death rates among women aged 40 to 49 years. *Can Med Assoc J*. 1992;147:1459-74 1993;148:718).
- [41] Marc ESPIE et André GORINS. Le sein. Ed. ESKA. Paris 1995. Chapitre 3 : Le cancer du sein ; pages 229-239.
- [42] Keita, K. I. (2022). Dépistage du cancer du sein dans le district sanitaire de Sikasso.
- [43] Sancho-Garnier, H., & Colonna, M. (2019). Épidémiologie des cancers du sein. *La Presse Médicale*, 48(10), 1076-1084.
- [44] CROS Nathalie. Epidémiologie et Santé: cancer du sein en France [en ligne]. France, INRP: Institut nationale de recherches pédagogiques,2005.Disponible sur: < <http://acces.inrp.fr/acces/ressources/sante/epidemiologie/cancersein>> .25/05/2023
- [45]Mahnane, A., & Cherif, M. H. (2012). Epidémiologie du cancer du sein en Algérie. Actualités dans la prise en charge multidisciplinaires des cancers du sein.20/04/2023

- [46] Elmore JG, Barton MB, Mocerri VM, Polk S, Arena PJ, Fletcher SW. Ten-year risk of false positive screening mammograms and clinical breast examinations. N Engl J Med. 1998;338:1089-96 .29/04/2023
- [47] Sun YS, Zhao Z, Yang ZN, Xu F, Lu HJ, Zhu ZY, Shi W, Jiang J, Yao PP, Zhu HP. Facteurs de risque et prévention du cancer du sein. Int J Biol Sci. 2017 Nov 1;13(11):1387-1397. doi: 10.7150/ijbs.21635. PMID : 29209143; PMCID : PMC5715522.
- [48] American cancer society : Le cancer du sein. [en ligne]. Etats-Unis, 2010. Disponible sur : < <http://www.cancer.org/Cancer/BreastCancer/DetailedGuide/breast-cancerstaging>. 05/05/2023
- [49] Sharma, G. N., Dave, R., Sanadya, J., Sharma, P., & Sharma, K. (2010). Various types and management of breast cancer: an overview. Journal of advanced pharmaceutical technology & research, 1(2), 109.
- [50] Kolb TM, Lichy J, Newhouse JH. Occult cancer in women with dense breasts: detection with screening US—diagnostic yield and tumor characteristics. Radiology. 1998;207:191-9.
- [51] Docteur BENCHIMOL. Le cancer du sein [en ligne]. Paris, 2006. Disponible sur: < [http://www.docteur-benchimol.com/cancer\\_du\\_sein.html](http://www.docteur-benchimol.com/cancer_du_sein.html) >. 09/05/2023
- [52] Le profil biologique des patientes atteintes par le cancer du sein traitées par chimiothérapie au centre de lutte contre le cancer de Draa Ben Khedda, BEN FODIL Amina ,BELGRINE Ahmed BEN ,CHIKH Meriem, KADDACHE Salim, 11/05/2023
- [53]<https://www.e-cancer.fr/Patients-et-proches/Les-cancers/Cancer-du-sein/Les-maladies-du-sein/Cancers-du-sein> 13/05/2023
- [54] “The Python Tutorial — Python 3.8.6rc1 documentation <https://docs.python.org/3/tutorial/> 13/05/2023
- [55] “TensorFlow,” TensorFlow. <https://www.tensorflow.org/>. 13/05/2023
- [56] “K. Team, “ Keras documentation: About Keras. <https://keras.io/about/> 12/05/2023
- [57] “OpenCV.” <https://opencv.org/about/>. 11/05/2023
- [58] “ Pandas ” <https://pandas.pydata.org/>. 13/05/2023
- [59] “Colaboratory – Google. <https://research.google.com/colaboratory/faq.html#resource-limits> 13/05/2023

- [60] “Anaconda Navigator — Anaconda documentation.”  
<https://docs.anaconda.com/anaconda/navigator> /10/04/2023
- [61] “Project Jupyter . <https://www.jupyter.org>. 13/05/2023
- [62] “ DataSet MIAS” <https://www.kaggle.com/datasets/kmader/mias-mammography>.  
21/04/2023