



République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique



Université Amar Thelidji- Laghouat

FACULTE: DE TECHNOLOGIE
DEPARTEMENT D'ELECTRONIQUE

MEMOIRE DE MASTER

Réalisé par : MOUSLI khaled

CHETTOUH safieddine

DOMAINE :Science et Technologie

FILIERE : Electronique

OPTION : Electronique des systèmes embarqués

Thème

Classification des images de tumeurs cérébrales par résonance magnétique (IRM) en utilisant le Deep Learning

Jury de soutenance :

Nom et Prénom	Grade	Qualité
Mr Zitouni Abdelkader	MCB	Encadreur
Mr Deleci Mustapha	MAA.	Examineur
Mr Benkouider Fatiha	MCB	Examineur

Promotion : 2021/2022

Remerciements

Nous rendons nos profondes gratitude à Dieu tout puissant qui nous a aidés à réaliser ce modeste travail.

Nous exprimons nos profondes gratitude à nos parents pour leurs encouragements, leurs soutiens et pour les sacrifices qu'ils ont enduré.

Nous remercions, notre promoteur Mr Zitouni Abdelkader pour les efforts qu'il a déployé, pour nous aider, conseiller, encourager et corriger. Nous tenons à remercier les membres de jury d'avoir accepté d'examiner notre travail

Nous remercions aussi tout le corps enseignant dans le département d'électronique qui a contribué à notre formation universitaire.

Sans oublier tous nos amis Que tous ceux qui ont contribué de près ou de loin à la réalisation de ce travail, trouvent ici notre sincère reconnaissance.

Dédicaces

A mon père et ma mère

A mes Sœurs mes Frères A toute ma famille

A mon binôme

A tous mes ami(e)s, proches ou lointains, je vous dédie ce travail

*M. Khaled
CH. safieddine*

Sommaire

Sommaire

Remerciements	{A}
Dédicaces	{B}
Résumé.....	{C}
Table de figure et tables	{D}
Introduction générale.....	{3}

Chapitre I Notion de traitement d'images

I.1.Introduction :.....	{4}
• Qu'est-ce qu'une image ?.....	{4}
• Pourquoi et comment traiter les images ?.....	{6}
I.2. Notions fondamentales en traitement d'images :.....	{6}
I.2.1. Pixel :.....	{6}
I.2.2. Voisinage d'un pixel :.....	{7}
I.2.3. Image numérique :.....	{8}
I.2.4. Résolution d'une image :.....	{8}
I.2.5. L'imagerie médicale:.....	{8}
<i>I.2.5.1 La radiogra</i>	{8}
I.2.5.2 L'échographie :.....	{9}
I.2.5.3 La scanographie :.....	{10}
I.2.5.4mammographie:.....	{11}
I.2.5.5 L'imagerie par résonance magnétique:.....	{12}
I.2.6. Bruit dans l'image :.....	{14}
I.2.6. Histogramme :.....	{15}
I.2.7. Contraste :.....	{15}
I.3. Étapes de l'analyse d'images :.....	{16}

I.4. Domaines d'applications du traitement d'images :.....	{16}
I.5. Outils de traitement d'images :.....	{17}
I.5.1. Modification d'histogramme :.....	{17}
I.5.2. Binarisation (par seuillage) :.....	{18}
I.6. Réduction du bruit :.....	{18}
I.6.1. Filtres linéaires :.....	{19}
I.6.2. Filtres non linéaires :.....	{21}
I.6.3. Filtres morphologiques :.....	{22}
I.6.4. Filtres Adaptatifs.....	{23}
I.7. Conclusion :.....	{24}

Chapitre II Principes et concepts de base de l'intelligence artificielle

1. Introduction	{26}
1.1 Principe de l'intelligence artificielle:.....	{26}
1.2 Qu'est-ce que l'intelligence artificielle ?	{26}
❖ Définition 1	{27}
❖ Définition 2.....	{27}
2. Les domaines d'applications de L'IA	{27}
2.1 La santé	{28}
2.2 Le transport	{28}
2.3 Le commerce	{28}
2.4 L'agriculture intelligente.....	{28}
2.5 Le droit	{29}
3. Apprentissage Profond (Deep Learning).....	{29}
3.1 Définition et origines	{29}
4. Les réseaux de neurones artificiels.....	{30}
4.1 Définition.....	{30}

4.2 Architecture d'un réseau de neurones artificiel	{30}
4.3 Principe de fonctionnement d'un réseau de neurones artificiel.....	{31}
4.5 Types des réseaux de neurones	{32}
5. Les réseaux de neurones convolutifs (CNN : Convolution al neural networks.....	{32}
5.1 Définition d'un réseau neuronal convolutif.....	{34}
5.2 Architecture et fonctionnement d'un CNN.....	{34}
5.3 Partie convolution	{34}
5.3.1 Couche de convolution.....	{35}
5.3.2 Couches de correction (RELU).....	{36}
5.3.3 Couche Pooling (ou sous-échantillonnage).....	{37}
5.4 Partie classification	{38}
5.4.1 Couche Fully-connected (entièrement connecté)	{39}
6. Modèles CNN prédéfinis.....	{39}
6.1 LeNet	{40}
6.2 AlexNet.....	{40}
6.3 VGG16.....	{41}
6.4 GoogleNet.....	{42}
6.5 ResNet.....	{43}
7. Conclusion	{44}

Chapitre III Résultats et discussion

III.1 Introduction.....	{46}
III.2 Les Outils logiciels utilisés :	{46}
III.3 Définition de Matlab.....	{46}
III.4 Dataset.....	{47}
III.5 Architectures et paramètres des modèles CNNs utilisés dans l'implémentation.	{47}

III.6 Transfert learning:	{48}
III.7 Architecture d'AlexNet et de GoogleNet.....	{48}
III.8 Les paramètre d'AlexNet et de GoogleNet.....	{50}
III.9 Résultats et Discussion.....	{50}
III.10 Graphic interface	{55}
III.11 Segmentation sémantique des tumeurs cérébrales en utilisant les bibliothèques Deep Learning de python :	{55}
III.11.1Python:	{56}
III.11.2TensorFlow	{56}
III.11.3Keras:	{56}
III.11.4 Dataset :	{56}
III.11.5 L'architecture U-Net.....	{57}
III.11.6 Notre approche:	{59}
III.11.7 Graphic interface :	{62}
III.12 Conclusion	{64}
Références Bibliographie.....	{58}

Liste des figures

Et

Tableaux d'abréviations

Table de figure

CHAPITRE 1

Figure I.1 : Image en pixels.....	7
Figure I.2 : Voisinage d'un pixel.....	7
Figure I.3 <i>Radiographie cervical</i>	9
Figure I.4 <i>Radiographie du genou</i>	9
Figure I.5 <i>Echographie gastrique</i>	10
Figure I.6 <i>La tomodensitométrie (Tdm) cérébrale</i>	11
Figure I.7 <i>Tomographie : Scanner</i>	11
Figure I.8 <i>Mammographe</i>	12
Figure I.9 <i>IRM Cérébrale</i>	14
Figure I.10 : Histogramme d'image.....	15
Figure I.11 : Principe de la modification d'histogramme.....	17
Figure I.12 : Choix du seuil sur l'histogramme de l'image en niveaux de gris.....	18
Figure I.13 : Filtrage linéaire.....	19
Figure I.14 : Principe de fonctionnement du filtre médian.....	22

CHAPITRE 2

Figure II.1 : La relation entre l'IA, Machine Learning et Deep Learning.....	30
Figure II.2 : Architecture de base d'un réseau de neurones artificiel.....	31

Figure II.3: Principe de fonctionnement d'un réseau de neurones artificiel.....	32
Figure II.4 : le processus d'auto-apprentissage pour l'identification d'un chat	33
Figure II.5 : Architecture de base d'un réseau neuronal convolutif	35
Figure II.6 : La partie convolution d'un CNN	36
Figure II.7 : Parcours de la fenêtre de filtre sur l'image	36
Figure II.8 : Le principe de convolution	37
Figure II.9 : Fonctionnement de la fonction RELU.....	38
Figure II.11 : Le principe de Pooling avec un filtre 2*2 et un pas de 2.....	39
Figure II.12 : La couche Fully connected.....	40
Figure II.13 : Le fonctionnement d'un réseau de neurones à convolution.....	40
Figure II.14 : Visualisation de l'Architecture du réseau LeNet-5	40
Figure II.15 : Visualisation de l'architecture du réseau AlexNet	41
Figure II.16 : Visualisation de l'architecture du réseau VGG16.....	41
Figure II.17 : Visualisation de l'architecture du réseau GoogleNet (1).	42
Figure II.18 : Visualisation de l'architecture du réseau GoogleNet (2).....	42
Figure II.19 : Visualisation de l'architecture du réseau ResNet.....	43

CHAPITRE 3

Figure III.1 : Images par résonance magnétique du cerveau d'une personne en bonne santé et d'autre malades.....	47
Figure III.1 : Progression de l'apprentissage du réseau AlexNet avec augmentation des données.....	51
Figure III.2 : Résultats obtenus, dans quelque image de test, par l'utilisation du modèle AlexNet.....	52
Figure III.3 : Progression de l'apprentissage du réseau GoogleNet avec augmentation des données.....	53
Figure III.3 : Résultats obtenus, dans quelque image de test, par l'utilisation du modèle GoogleNet.....	54
Figure III.4 : Interface graphique représente les résultats final.....	56
Figure III.5 : Architecture du réseau de neuronesU-Net.....	58
Figure III.6 : Quatre canaux d'information et le mask d'une image de la base BraTS 2020.....	60
Figure III.7 :Résultats obtenus sur quelques images de test de la base BraTS 2020.....	61
Figure III.8 : Interface graphique représente les résultats obtenus.....	63

Liste des Tableaux

Tableau III.1 : Tableau représentant les paramètres des modèles AlexNet et GoogleNet.....	50
Tableau III.2 : Accuracy obtenue dans l'ensemble d'images d'apprentissage et de test, en utilisons le modèle AlexNet.....	53
Tableau III.3 : Accuracy obtenue dans l'ensemble d'images d'apprentissage et de test, en utilisons le modèle GoogleNet.....	55

ملخص

يستخدم الذكاء الاصطناعي ، الذي يعتبر ذكاء توفره آلة ، لتطوير العديد من المجالات، بما في ذلك الصحة والصناعة والتجارة والزراعة. أورام الدماغ هي أكثر الأمراض شيوعاً وخطورة ، مع متوسط عمر قصير نسبياً في أشد أشكالها. وبالتالي ، يعد تخطيط العلاج خطوة مهمة في تحسين نوعية حياة المرضى. في هذا العمل ، اقترحنا طريقة توضح استخدام شبكة التعلم العميق لأداء تجزئة ورم الدماغ في التصوير بالرنين المغناطيسي (MRI). أثناء عملنا ولكي نكون قادرين على إجراء التصنيف التلقائي لمجموعة الصور ، اعتمدنا نموذجين لشبكة CNN هما AlexNet و GoogleNet يقدم نموذجاً CNNs اللذان اعتمدناهما في عملنا نتائج جيدة في تصنيف صور التصوير بالرنين المغناطيسي لأورام الدماغ. كجزء ثانٍ ، استخدمنا شبكة التعلم العميق ثلاثية الأبعاد- U-Net لإجراء تقسيم دلالي ثنائي لأورام الدماغ في صور التصوير بالرنين المغناطيسي. النهج المقترح للتجزئة الدلالية في قاعدة بيانات BraTS 2020 يعطي نتائج جيدة.

الكلمات المفتاحية: الذكاء الاصطناعي ، التصوير بالرنين المغناطيسي ، أورام الدماغ ، التعلم العميق ، التقسيم الدلالي ، الشبكة العصبية الانعكافية.

Abstract

Artificial intelligence is used to develop and advance many fields, including health, industry, commerce and agriculture. Brain tumors are the most common and aggressive disease, with a relatively short life expectancy in their most severe form. Thus, treatment planning is an important step in improving the quality of life of patients. In this work we have proposed a method that illustrates the use of deep learning network to perform brain tumor segmentation in magnetic resonance imaging (MRI). During our work and in order to be able to achieve the automatic classification of the set of images, we adopted two CNNs models namely AlexNet and GoogleNet. The two CNNs models that we have adopted in our work give good results in the classification of MRI images of brain tumors. As a second part we used a 3-D U-Net deep learning network to perform a binary semantic segmentation of brain tumors in MRI images. The approach proposed for semantic segmentation in the BraTS 2020 database gives good results.

Keywords : Artificial Intelligence, MRI Imaging, Brain Tumors, Deep Learning, Semantic Segmentation,

Résumé

L'intelligence artificielle, considérée comme étant une intelligence fournie par une machine, est utilisée pour développer et faire progresser de nombreux domaines, y compris la santé, l'industrie, le commerce et le domaine d'agriculture. Les tumeurs cérébrales sont la maladie la plus courante et la plus agressive, avec une espérance de vie relativement courte dans leur forme la plus grave. Ainsi, la planification du traitement est une étape importante dans l'amélioration de la qualité de vie des patients. Dans ce travail nous avons proposé une méthode qui illustre l'utilisation de deep learning network pour effectuer une segmentation des tumeurs cérébrales dans l'imagerie par résonance magnétique (IRM). Au cours de notre travail et afin de pouvoir réaliser la classification automatique de l'ensemble d'images, nous avons adopté deux modèles CNNs à savoir AlexNet et GoogleNet. Les deux modèles CNNs que nous avons adopté dans notre travail donne de bons résultats en classification d'images IRM de tumeurs cérébrales. Comme deuxième partie nous avons utilisé un 3-D U-Net deep learning network pour effectuer une segmentation sémantique binaire des tumeurs cérébrales dans l'imagerie IRM. L'approche proposée pour faire la segmentation sémantique dans la base BraTS 2020 donne des bons résultats.

Mots clés : Intelligence artificielle, Imagerie IRM, Tumeurs cérébrales, Apprentissage profond, Segmentation sémantique, Réseau neuronal convolutif.

Tableaux d'abréviations

Les Abréviation

TDM : Tomodensitométrie

IRM : Imagerie par **R**ésonance **M**agnétique

IA : Intelligence **A**rtificielle

MLP : **M**ulti **L**ayer **P**erception

CNN : **C**onvolutionnal **N**eural **N**etwork

DL: **D**eep **L**earning

ML: **M**achine **L**earning

RELU: **R**ectified **L**inear **U**nit

LN: **L**e**N**et

AN: **A**lex**N**et

GN: **G**oogel**N**et

RN: **R**es**N**et

Introduction générale

Introduction générale

Actuellement, nous sommes devant un début d'une nouvelle notion technologique qui est l'intelligence artificielle qui n'épargnera aucun secteur. La présence d'un grand nombre d'algorithmes, la croissance de la puissance de calcul, la disponibilité d'une énorme quantité de données stockée dans des bases reliées entre elles grâce à des réseaux de plus en plus rapide, disponibles sur des machines connectées en permanence va avoir un impact immense sur la vie humaine [1].

L'intelligence artificielle est devenue donc un sujet d'une importance majeure dans notre époque, car cette évolution technologique a pu résoudre plusieurs problèmes complexes, chose que les autres technologies n'ont pas pu réussir à faire. Cette notion n'est pas rupture technologique mais plutôt elle est considérée comme une continuité de l'informatique [1].

L'intelligence artificielle, considérée comme étant une intelligence fournie par une machine, est utilisée pour développer et faire progresser de nombreux domaines, y compris la santé, l'industrie, le commerce et le domaine d'agriculture [1].

Les tumeurs cérébrales sont la maladie la plus courante et la plus agressive, avec une espérance de vie relativement courte dans leur forme la plus grave. Ainsi, la planification du traitement est une étape importante dans l'amélioration de la qualité de vie des patients. En général, des méthodes d'imagerie telles que la tomodensitométrie (TDM), l'imagerie par résonance magnétique (IRM) et les images échographiques sont utilisées pour évaluer les tumeurs du cerveau, des poumons, du foie, du sein, de la prostate, etc. [2]

La segmentation sémantique d'images médicales consiste à assigner chaque pixel de l'image à une étiquette bien précise, par exemple l'appartenance à un organe donné, et donc détecter certaines malformations, des anomalies ou des tumeurs et par conséquent, aider les médecins à suggérer un diagnostic approprié [1].

Il existe plusieurs architectures de réseaux de neurones standard qui ont apporté des contributions significatives au domaine de la vision par ordinateur étant souvent utilisés comme base des systèmes de segmentation sémantique. On peut citer en guise d'exemple : AlexNet, ResNet, VGG-16 et GoogLeNet et bien évidemment le U-Net [1].

Dans ce travail nous proposons une méthode qui illustre l'utilisation de deep learning network pour effectuer une segmentation des tumeurs cérébrales dans l'imagerie par résonance magnétique (IRM).

Pour atteindre notre objectif, nous avons déterminé plusieurs étapes, chacune d'elles est associée à un chapitre de ce mémoire dont :

Le premier chapitre introduit des généralités et quelques définitions fondamentales relatives au domaine du traitement d'images, et les algorithmes de prétraitement nécessaires pour améliorer la qualité de l'image.

Le second chapitre s'intéresse au principes et concepts de base de l'intelligence artificielle (IA) et les algorithmes mis en œuvre pour ces concepts.

Dans le troisième chapitre nous présenterons les résultats obtenus et les interprétations correspondantes. Nous concluons par une synthèse du travail effectué.

Chapitre I

Notion de traitement d'images

1. Introduction

Avec la parole, l'image a toujours constituée l'un des moyens le plus privilégié qu'utilise l'homme pour communiquer avec autrui. En effet c'est un moyen de communication universel dont la richesse du contenu permet aux êtres humains de tout âge et de toute culture de se comprendre. Chacun peut analyser l'image à sa manière, pour en dégager une impression et d'en extraire des informations précises.

De ce fait, le terme générique traitement d'images est l'ensemble des méthodes et techniques opérant sur celles-ci, dans le but de rendre cette opération possible, plus simple, plus efficace et plus agréable, d'améliorer l'aspect visuel de l'image et d'en extraire des informations jugées pertinentes en regard de l'application concernée[3].

Avant de donner les notions fondamentales et les outils de traitement d'images, il serait utile de définir la notion d'image et les raisons de son traitement.

• Qu'est-ce qu'une image ?

L'image est une représentation d'une personne ou d'un objet par la peinture, la sculpture, le dessin, la photographie, le film, etc.

C'est aussi un ensemble structuré d'informations qui, après affichage sur écran, ont une signification pour l'œil humain.

Afin que l'image puisse être traitée par la machine, sa numérisation est nécessaire.

Nous distinguons trois groupes d'images : [3]

1. Les images physiques visibles, qui sont parfaitement matérielles et de nature volatile (soit des images optiques, constituées de photons dans le domaine visible, soit les images électro-optiques), ou de nature permanente (reproductions de toutes sortes : clichés photographique, peintures, sculptures, documents, imprimés, etc.

2. Les images physiques non visibles, les images optiques hors du domaine visible ou images de nature immatérielle (spectres de physique, cartes de population, de températures, etc.). Une vue infrarouge est une image non visible mais, après impression d'une pellicule sensible à ce rayonnement, elle devient une image physique visible.

3. Les images mathématiques, qui sont des concepts et sont donc invisibles par nature. Elles peuvent être continues (par exemple une fonction $f(x, y)$) ou discrètes : ce sont alors des tableaux ou matrices de nombres.

• Pourquoi et comment traiter les images ?

On peut dire que l'on traite des images dès lors que l'on extrait une information de cette image. Il existe de très nombreuses façons de traiter des images. Une première manière de tenter une classification des types de traitement est de se référer au but poursuivi.

Pourquoi cherche-t-on à traiter une image ? [3]

1. On peut chercher à améliorer sa qualité subjective (la rendre plus agréable à l'œil) ou objective, donc mesurable : on veut améliorer son contraste, accroître la perception de certains détails ou contours, faire ressortir plus nettement certaines zones ou certaines formes, diminuer le bruit, etc. Il s'agit donc de techniques d'amélioration qui font appel à des procédés variés créant des lissages, rehaussements, etc.

2. On peut chercher à trouver une image « idéale » de l'objet qui a été dégradé par divers processus : on veut diminuer les fluctuations dues à des phénomènes de turbulence. Il s'agit là de techniques de restauration.

3. On peut chercher à détecter la présence de certaines formes, certains contours ou certaines textures de modèle connu, sans vouloir préserver les autres informations.

4. On peut chercher à réduire l'énorme quantité d'informations contenues dans une image, à la « comprimer » afin de gagner en vitesse de transmission, en encombrement des organes utilisés, en capacité de stockage, etc. tout en ne dégradant que le moins possible les images considérées. Ce domaine est celui du codage, de la compression des données et de l'approximation des images.

5. On peut chercher à faire une analyse de l'image. Cette dernière consiste en l'extraction des informations contenues dans les divers objets de la scène, sans toutefois fournir une interprétation. Il s'agit des techniques d'extraction d'attributs, c'est-à-dire de « formes » (contours, textures) et de segmentations.

Durant ce chapitre nous verrons

Les différents types d'imagerie médicale et quelques notions fondamentales, ainsi que quelques outils de traitement d'images.

2. Notions fondamentales en traitement d'images**2.1 Pixel**

Abréviation de « Picture Élément », mot anglo-américain de paix pour pics, abréviation de « Picture » (image) et el pour « élément ». Élément d'image, le pixel est le plus petit point de l'image, c'est une entité calculable qui peut recevoir une structure et une quantification.

La lettre A, par exemple, peut être affichée comme un groupe de pixels dans la figure I.1.



Figure I.1 : Image en pixels.

La quantité d'information que véhicule chaque pixel donne des nuances entre images monochromes et images couleurs. Dans le cas d'une image monochrome, chaque pixel est codé sur un octet, et la taille mémoire nécessaire pour afficher une telle image est directement liée à la taille de l'image.

Dans une image couleur (R.V.B.), un pixel peut être représenté sur trois octets : un octet pour chacune des couleurs : rouge (R), vert (V) et bleu (B) [1.8].


2.2 Voisinage d'un pixel

Le voisinage d'un pixel est composé de tous les pixels qui l'entourent immédiatement. Si p est un pixel d'une image D , alors le voisinage de p est le plus petit sous-ensemble de D qui contient p .


Dans une image numérique, on distingue deux types de connexités relatives au voisinage utilisé :

La 4-connexité (Figure I.2.a) et la 8-connexité (Figure I.2.b).

Le voisinage d'un pixel (i,j) est dit 4-connexe s'il est formé des quatre pixels de coordonnées spatiales $(i+1,j), (i,j+1), (i-1,j), (i,j-1)$, et il est dit 8-connexe s'il est formé des pixels de coordonnées spatiales $(i+1,j), (i,j+1), (i-1,j), (i,j-1), (i+1,j-1), (i+1,j+1), (i-1,j+1), (i-1,j-1)$ [1.9].



b) Voisinage 4-connexes



a) Voisinage 8-connexe

Figure I.2 : Voisinage d'un pixel.

2.3 Image numérique

Contrairement aux images obtenues à l'aide d'un appareil photo, ou dessinées sur du papier, les images manipulées par un ordinateur sont numériques (représentées par une série de bits).

L'image numérique est l'image dont la surface est divisée en éléments de tailles fixes appelés cellules ou pixels, ayant chacun comme caractéristique un niveau de gris ou de couleurs prélevé à l'emplacement correspondant dans l'image réelle, ou calculé à partir d'une description interne de la scène à représenter [3].

2.4 Résolution d'une image

La résolution d'une image est définie par un nombre de pixels par unité de longueur de la structure à numériser (classiquement en dpi (dots par inches) ou ppp (points par pouce)). Ce paramètre est défini lors de la numérisation et dépend principalement des caractéristiques du matériel utilisé lors de processus de numérisation. Plus le nombre de pixels est élevé par unité de longueur de la structure à numériser, plus la quantité d'information qui décrit cette structure est importante et plus la résolution est élevée. La résolution d'une image numérique définit le degré de détail qui va être représenté sur cette image [1.8].

2.5 L'imagerie médicale

L'imagerie médicale est un ensemble d'images du corps humain obtenues à l'aide de différents phénomènes physiques tels que la résonance magnétique, les ultra-sons, les rayons gamma et plusieurs autres effets employés selon l'objectif. Les tissus, les organes, leurs mouvements, les cellules et presque toute l'anatomie peuvent être visualisés sur un écran informatique.

L'imagerie médicale est un outil de diagnostic très puissant en plus d'être fréquemment utilisée dans la recherche. Son principal objectif est d'obtenir une image médicale révélant un ensemble d'informations précises sur le fonctionnement d'un organe comme le cœur et ses artères ou tout autre organe nécessitant un diagnostic ou une approche chirurgicale. L'image obtenue d'un organe ou d'un tissu est analysée directement par visionnement sur un écran.

Il existe différents types d'imagerie médicale :

1.2.5.1 La radiographie

La radiographie est un examen diagnostique qui utilise les rayons X. De la même famille que les rayons lumineux, mais de longueur d'onde plus courte, les rayons X ont la propriété de pouvoir impressionner une plaque radiographique, de la même

manière que la lumière, un film photographique. Cependant, contrairement à la photo la radiographie ne donne pas une image de notre enveloppe corporelle.

Comme les rayons X traversent la matière, le film radiographique peut garder l'impression et livrer l'image de notre anatomie interne. En fonction de l'organe radiographié, le cliché sera plus ou moins noirci.

Ainsi, sur une radio, les structures osseuses, qui absorbent le rayonnement, apparaîtront en blanc et les organes, tels que les poumons, en noir. Connus pour leur propriété de pénétration de la matière, les rayons X le seront aussi rapidement pour leur nocivité. C'est donc entourées des mesures de sécurité nécessaire, que les techniques radiographiques se diversifieront et se spécialiseront grâce au procédé de visualisation d'organes par injection de produits de contraste (ex : l'artériographie, radio des artères) ou bien plus tard, grâce à la numérisation des images (scanner à rayons X...) [4].



Figure I.3 *Radiographie cervicale*



Figure I.4 *Radiographie du genou*

2.5.2 L'échographie

L'échographie est un examen diagnostique basé sur l'utilisation d'ultrasons, c'est-à-dire de vibrations sonores supérieures à 20.000 Hertz, inaudibles à l'oreille humaine. Une échographie est réalisée à l'aide d'une machine génératrice de haute fréquence d'ultrasons, reliée à une sonde émettrice/réceptrice et contenant un système informatique capable de transformer les informations détectées par la sonde.

Les ultrasons produits par la machine sont transmis à la sonde que le médecin déplace sur la peau ou à l'intérieur de la partie du corps à explorer. Le faisceau d'ultrasons est arrêté par l'air et par les os, il se propage, par contre, aisément dans les

milieux liquides et pénètre tout aussi facilement les organes internes mous et pleins. L'ensemble des informations recueillies donne une image anatomique en coupe, permettant de visualiser les organes [5]

L'échographie présente de nombreux avantages. Simple et indolore, cet examen peut surtout être répété à volonté : contrairement à la radiographie, il n'émet en effet aucun rayonnement nocif.



Figure I.5 Echographie gastrique

2.5.3 La scanographie

Le Scanner appelé aussi tomodynamométrie, est un examen qui utilise les rayons X. Son principe consiste à réaliser des images en coupes fines du corps humain. Au lieu d'être fixe, le tube de rayons X va tourner autour du corps et grâce à un système informatique puissant, des images sont obtenues. Ensuite, elles sont imprimées sur un film pour être étudiées. Dans la plupart des cas, un produit de contraste à base d'iode est utilisé pour améliorer leur qualité. Il peut être injecté par voie intraveineuse, avalé ou encore introduit par l'anus [6].

Dans la salle d'examen, on trouve :

- La machine qui se compose d'un anneau à l'intérieur duquel se trouve le tube à rayons X et d'une couchette sur laquelle vous êtes allongé, qui pénètre dans le centre de l'anneau.
- Le pupitre de commande derrière lequel se trouve le personnel médical est séparé du reste de la pièce par une vitre plombée.

Cet examen présente l'avantage de donner des informations très précises sur les organes étudiés. De l'extérieur du corps, on peut le découper en tranches ou le reconstruire en trois dimensions. [6].



Figure I.6 *La tomodensitométrie (Tdm) cérébrale*



Figure I.7 *Tomographie : Scanner*

2.5.4 La mammographie

La mammographie est un examen radiologique consacré à la détection des pathologies du sein. Cet examen s'effectue avec un appareil dédié uniquement à cet usage: le mammographe. Cet appareillage utilise les rayons X pour produire des images de hautes résolutions du sein. Les différences d'absorption des rayons X par le tissu mammaire permettent de former une image qui révèle l'architecture du sein.

L'utilité de cet examen se trouve surtout dans la détection de la désorganisation de l'architecture du sein, de masses ou de foyers de microcalcifications, qui peuvent révéler la présence d'un cancer.

On doit distinguer la «mammographie diagnostique» de la «mammographie de dépistage».

La mammographie diagnostique est effectuée chez des personnes symptomatiques : une masse a été palpée dans le sein ; il existe un écoulement sanguinolent à travers le mamelon. Dans ces situations, la mammographie est réalisée pour caractériser la masse palpée ou pour rechercher une tumeur. Ce type de mammographie est toujours pris en charge par les assurances maladie.

La mammographie de dépistage recherche la présence d'une tumeur chez des personnes non symptomatiques.

On distingue encore le dépistage personnalisé (organisé par le médecin traitant sur demande de la patiente) du dépistage systématique [7]



Figure I.8 Mammographe

2.5.5 L'imagerie par résonance magnétique IRM

L'IRM ou imagerie par résonance magnétique, fait partie des examens complémentaires d'imagerie médicale, tout comme la radiographie, l'échographie, ou le scanner. Cette technique très sophistiquée permet de réaliser des images du corps humain, qui aideront le médecin à faire un diagnostic. Il faut souligner d'emblée que l'IRM ne remplace pas les autres techniques d'imagerie, mais elle les complète.

Les radiographies standards sont toujours nécessaires et la plupart du temps prescrites avant une IRM.

Techniquement, les images sont réalisées grâce à un champ magnétique produit par un aimant (il n'y a pas de rayons X), dans lequel passe des ondes radio qui vont faire « résonner » les atomes d'hydrogène du corps. C'est un système

informatique qui, en fonction des informations renvoyées par l'organisme, va composer une image numérique, qui sera imprimée sur un film.

Le patient est accueilli par un technicien (ou une technicienne) qui l'installera "dans l'IRM". Au préalable, le patient laisserait dans une cabine de déshabillage, ses prothèses dentaires et auditives amovibles, ses lunettes, bijoux, épingles à cheveux et montre, ses chaussures, ceintures et tous objets métalliques contenus dans ses poches (pièces de monnaie, clés, stylo...). Les cartes à piste magnétique sont détruites par l'IRM, mieux vaut donc ne pas les garder sur soi. Les téléphones cellulaires seraient aussi endommagés.

Pendant l'examen, le patient est allongé sur un lit confortable, vous entendez un bruit fort de martelage entrecoupé de silence. Vous êtes en permanence en contact avec l'opérateur qui peut vous entendre et vous parler par l'intermédiaire d'un interphone. L'examen dure entre 15 et 40 minutes. Parfois il est nécessaire d'injecter un produit en intra veineux au pli du coude pour améliorer les images.

Une injection intra veineuse de "produit de contraste" peut être nécessaire pendant l'examen, pour améliorer la qualité de certaines images et donc faciliter le diagnostic.

L'IRM est un examen inoffensif, si l'on respecte les contre-indications. Pour que les images soient exploitables par le médecin, votre coopération avec l'équipe de techniciens est indispensable. Cet examen peut être réalisé chez l'enfant, même très jeune, il peut nécessiter une légère prémédication sédatrice, celle-ci n'est la plupart du temps pas nécessaire, un des parents pouvant rester à côté de l'enfant en salle d'IRM.

L'examen en IRM permet de faire des coupes dans les 3 plans: horizontal, vertical et transversal. Les radiologues leur donnent les noms de: Coupes coronale, axiale et sagittale. Les coupes axiales permettent d'analyser la rotule, son positionnement et le cartilage entre rotule et fémur (fémoro-patellaire), les épanchements liquidiens apparaissent nettement, le tissu synovial est aussi bien vu.

Les coupes coronales montrent bien les ménisques, les ligaments latéraux (internes et externes, LLI et LLE), les cartilages fémoro-tibiaux, et à un moindre titre les ligaments croisés [8].

Les coupes sagittales permettent d'apprécier l'état des ménisques, des ligaments croisés, antérieurs et postérieurs. Les tendons rotuliens et quadricipitaux sont aussi très bien vus.

L'IRM est un examen très performant qui ne fait que se développer, il permet des diagnostics, de plus en plus précis et donc des traitements plus affinés.

Malheureusement, les délais de rendez-vous sont souvent long, car les machines sont rares et grande est la demande.

Il faut tout de même savoir que l'IRM n'est pas l'examen suprême, celui "qui voit tout", comme si le patient entrait dans un "tube-couloir" à la sortie duquel il aurait son diagnostic et son traitement. Cette image fait encore partie de la science fiction. L'imagerie par résonance magnétique fait partie de la batterie d'examens dont dispose le médecin pour faire son diagnostic et donc adapter un traitement.

Elle ne remplace pas les autres examens ; les radiographies standards sont encore d'actualité, elles doivent d'ailleurs, presque toujours, être exécutées avant l'IRM,

L'échographie garde son intérêt, dans bien des cas et le scanner est parfois bien meilleur que l'IRM dans certaines pathologies.




Figure I.9 IRM Cérébrale

2.6. Bruit dans l'image

Le bruit dans une image est défini comme étant un phénomène de brusque variation d'un pixel isolé par rapport à ses voisins, il affecte la qualité de l'image et il provient soit du dispositif d'acquisition (scanner, caméra, amplification, quantification...) soit de la scène elle-même (poussières, rayures...)[3].

2.6. Histogramme

L'histogramme des niveaux de gris ou des couleurs d'une image est une fonction qui donne la fréquence d'apparition de chaque niveau de gris (couleur) dans l'image. Pour diminuer l'erreur de quantification, pour comparer deux images obtenues sous des éclairages différents, ou encore pour mesurer certaines propriétés sur une image, on modifie souvent l'histogramme correspondant [3].

Il permet de donner un grand nombre d'informations sur la distribution des niveaux de gris (couleur) et de voir entre quelles bornes est répartie la majorité des niveaux de gris (couleur) dans les cas d'une image trop claire ou d'une image trop foncée. (Figure I.3) [3]

Il peut être utilisé pour améliorer la qualité d'une image (Rehaussement d'image) en introduisant quelques modifications, pour pouvoir extraire les informations utiles de celle-ci.




Figure I.10 : Histogramme d'image.

2.7. 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 [9].

Si $L1$ et $L2$ sont les degrés de luminosité respectivement de deux zones voisines $A1$ et $A2$ d'une image, le contraste C est défini par le rapport :

$$C = \frac{L1 - L2}{L1 + L2} \quad (I.1)$$

3. Étapes de l'analyse d'images

La plupart des applications de traitement d'image passent par les étapes suivantes : [3]

- Acquisition : Echantillonnage, Quantification.
- Analyse globale de l'image et transformations ponctuelles : Histogramme ; statistiques (moyenne, écart-type, etc.) ; transcodage (palette de couleur [LUT]) et classification.
- Opérations entre images : Indices, ratio, différence, opérations logiques, masques et seuillage.
- Amélioration, filtrage et segmentation : Opérations de convolution (lissage, rehaussement, détection de contours) ; squelettisation ; vectorisation.
- Interprétation et sémantique : Cartographie thématique (classification automatique et supervisée) ; cartographie vectrice ; représentation des graphes et de la topologie.

4. Domaines d'applications du traitement d'images

Le traitement d'images possède l'aspect multidisciplinaire. On trouve ses applications dans des domaines très variés tels que les télécommunications (T.V., vidéo, publicité,...), la médecine (radiographie, ultrasons,...), la biologie, l'astronomie, la géologie, l'industrie (robotique, sécurité), la météorologie, l'architecture, l'imprimerie, l'armement (application militaire).

De nouvelles applications pratiques sont possibles aujourd'hui et touchent tous les domaines d'activités, tels que : métiers du spectacle, de la radio, créations artistiques, etc. [1.8]

5. Outils de traitement d'images

La qualité d'une image peut être dégradée pour des raisons diverses. Les images brutes permettent rarement de parvenir à une extraction directe des objets à analyser :

- Soit parce que l'éclairage de l'objet n'est pas uniforme,
- Soit parce que le contraste n'est pas suffisant,
- Soit encore parce que l'objet est perçu à travers un bruit assez important : les images contiennent donc un signal et du bruit (dont on veut éliminer la plus grande partie possible).

Avant d'extraire les objets et d'analyser une image, il est donc souvent nécessaire d'améliorer sa qualité en lui appliquant quelques traitements (par exemple : modification d'histogramme, binarisation, amélioration du contraste, élimination de bruits, etc.).

Les traitements s'appliquent toujours aux images en niveau gris et parfois aussi sur des images couleurs. [9]

Nous allons présenter dans ce qui suit quelques types de ces traitements.

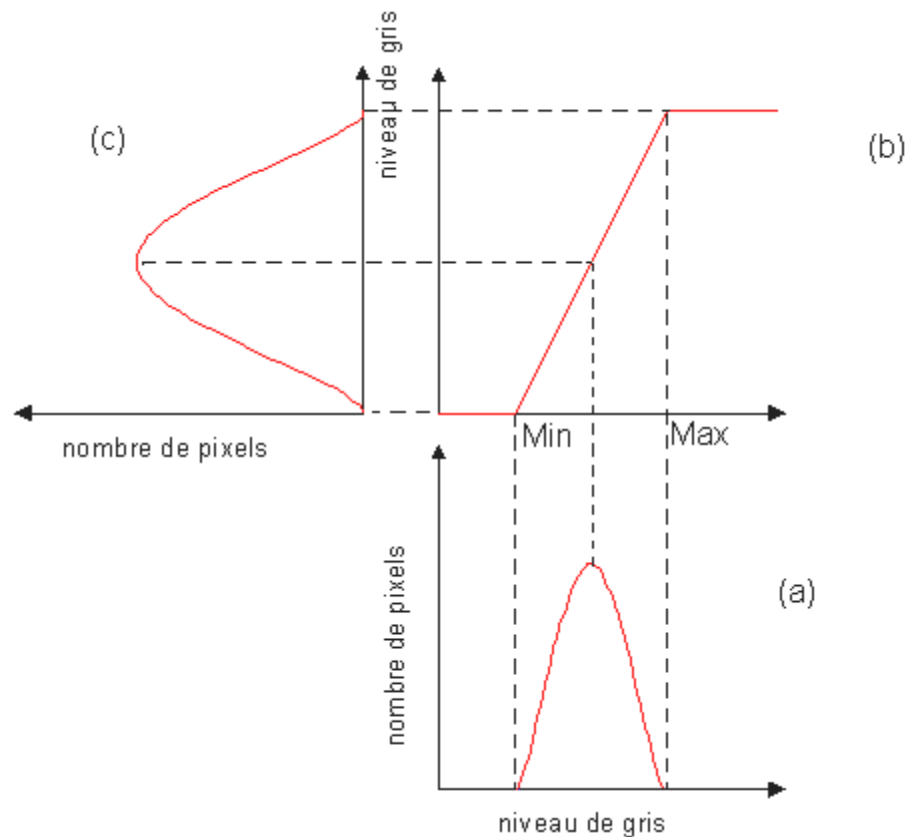
5.1. Modification d'histogramme

L'histogramme d'une image est une fonction qui donne la fréquence d'apparition de chaque niveau de gris (ou couleur) dans l'image, (voir I.2.6). Or parfois certaines images apparaissent trop foncées (les niveaux de gris de l'image sont tassés vers le haut de l'échelle), ou trop claires (les niveaux de gris de l'image sont tassés vers le bas de l'échelle), ou bien peu contrastées (les niveaux de gris de l'image sont regroupés dans un intervalle étroit).

De ce fait, afin d'améliorer l'image on est ramené à modifier son histogramme, qui a pour but de redistribuer les niveaux de gris de l'image afin de leur faire occuper toute la bande de nuance possible. (Figure I.4).

Cette méthode est basée sur les transformations ponctuelles d'intensité. C'est-à-dire, qu'à tout pixel d'intensité a on associe une intensité $a' = T(a)$.

Du fait de leur caractère ponctuel, les méthodes de transformation d'histogramme n'affectent pas la forme des régions. Elles en modifient uniquement l'apparence visuelle. [9]



a)- Histogramme de l'image originale.

b)- Fonction de transformation.

c)- Histogramme recadré.

Figure I.11 : Principe de la modification d'histogramme.

5.2. Binarisation (par seuillage)

Binariser une image en niveaux de gris consiste à la transformer en une image bi niveaux, c'est-à-dire attribuer à chaque pixel de l'image la valeur 0 « noir » ou 255 « blanc ». La dynamique de l'image est alors réduite à deux luminosités. La mise en œuvre la plus simple est de fixer un seuil ajustable, identique pour toute l'image. Pour une échelle à 256 niveaux de gris, cette valeur est comprise entre 0 et 255, généralement dans la plage médiane, chaque pixel est comparé à ce seuil en polarité directe, ceux de niveaux de gris inférieurs sont mis à « blanc » (0), ceux supérieurs mis à « noir » (1).

La difficulté réside dans le choix du seuil. Si le seuil est fait par le scanner un opérateur peut effectuer un réglage en fonction de l'aspect visuel du document et du résultat d'une première acquisition. Pour le seuillage automatique d'une image à niveaux de gris, une méthode consiste à tracer un histogramme de ces niveaux de gris, et choisir le seuil au fond de la vallée qui sépare le pic correspondant au niveau de gris du fond et le premier pic suivant (Figure I.5). [10]




Figure I.13: Choix du seuil sur l'histogramme de l'image en niveaux de gris.

6. Réduction du bruit

Le transfert de l'image d'un objet jusqu'à l'ordinateur lors de l'acquisition des images se produit avec un certain bruit. Le bruit est dû en particulier aux imperfections de la source qui génère l'image, au capteur proprement dit (caméra, détecteur électronique, etc.), et enfin à toute l'électronique de transfert. [9]

L'amélioration de l'image est essentiellement obtenue par ce que l'on appelle une opération de filtrage.

Il existe un grand nombre de filtres, que l'on peut classer en 4 grandes catégories :

- Les filtres linéaires.
- Les filtres non linéaires.
- Les filtres morphologiques.
- Les filtres optimaux.

6.1. Filtres linéaires

La transformation de chaque pixel est le fruit d'une combinaison linéaire des pixels voisins. Ces opérateurs sont caractérisés par leur réponse impulsionnelle $h(x, y)$. [10]

La relation entrée-sortie est décrite par l'équation de convolution :

$$C(x, y) = A * h(x, y) = \iint A(\alpha, \beta) h(x - \alpha, y - \beta) d\alpha d\beta \quad (1.2)$$




Figure I.14 : Filtrage linéaire.

Dans le cas d'une image numérique, l'équation (I.2) est remplacée par la relation de convolution discrète :

$$D[i, j] = \sum_m \sum_n h[m, n] A[i - m, j - n] = \sum_m \sum_n A[m, n] h[i - m, j - n] \quad (\text{I.3})$$

Il existe une grande variété de filtres plus ou moins utilisés et il serait fastidieux de vouloir tous les décrire, notre choix sera porté sur les filtres linéaires les plus courants, parmi eux on définit :

- Le filtre moyen.
- Le filtre gaussien.

• Filtre moyen

Il consiste à considérer chaque point de l'image et d'en faire la moyenne avec les huit pixels qui lui sont voisins. Ceci va avoir pour effet d'adoucir l'image en réduisant les fluctuations des niveaux de gris.

Ce type de filtre utilisant la moyenne non pondérée des voisins peut être mis sous la forme d'un masque tel que celui-ci :

$$H_1 = \frac{1}{9} \begin{pmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{pmatrix}$$

On va alors déplacer ce masque sur toute l'image, le pixel affecté par la transformation étant le pixel central du masque. Le facteur $1/9$ est égal à la somme des coefficients du masque et sert à normaliser le filtre de manière à ce que celui-ci n'influe pas sur l'intensité globale de l'image.

Si nous posons I_B comme étant l'image de départ (image bruitée), I_f l'image résultat (image filtrée), toutes deux de taille $p \times p$, et H_I le masque, nous avons alors pour chaque pixel de coordonnées x, y :

$$I_f(i, j) = \frac{1}{9} \sum_{j=-1}^1 \sum_{j=-1}^1 H_1(i+1, j+1) \cdot I_B(x+i, y+j) \quad (\text{I.4})$$

D'autres filtres ont été réalisés en utilisant des coefficients de pondérations différents. Par exemple :

$$H_2 = \frac{1}{10} \begin{pmatrix} 1 & 1 & 1 \\ 1 & 2 & 1 \\ 1 & 1 & 1 \end{pmatrix} \quad H_3 = \frac{1}{16} \begin{pmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{pmatrix}$$

Le filtre H_2 donne plus de poids au pixel central, ce qui le rend moins actif que le filtre H_1 , le filtre H_3 privilégie les directions x et y .

• Filtre gaussien

Il représente un filtre linéaire parmi les plus courants, tant par sa facilité de mise en œuvre que par la bonne qualité de ses résultats. Ce filtre tire son nom de la valeur de ses coefficients qui sont ceux d'une courbe de Gauss à deux dimensions.

Un filtre gaussien consiste en la convolution d'une image I_B avec une gaussienne $G(x, y, \sigma)$:

$$I_f = G \otimes I_B \quad (\text{I.5})$$

Avec :

$$G(x, y, \sigma) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{x^2 + y^2}{2\sigma^2}\right) \quad (\text{I.6})$$

Où G est un masque carré dont les coefficients sont les éléments discrétisés de la gaussienne. Le principal avantage du filtre gaussien est qu'il présente le meilleur compromis entre les localisations spatiales et fréquentielles.

6.2. Filtres non linéaires

Ce type de filtre s'oppose au précédent dans sa dénomination car il n'est pas le résultat d'une combinaison linéaire de pixels, les pixels voisins interviennent suivant une loi non linéaire. Le domaine du filtrage non linéaire est extrêmement vaste, l'exemple le plus classique de filtre non linéaire est le filtre médian de Tuckey.

• Filtre médian

Son principe est celui de la figure I.7 et il peut être décomposé selon les étapes suivantes : Pour chaque pixel de l'image

- On classe les pixels voisins du pixel courant (compris dans la fenêtre) par valeurs croissantes.

- On prend la valeur médiane des pixels classés et on l'affecte au pixel courant.

5	6	7
6	111	8
7	8	9

le filtre médian va considérer les valeurs du voisinage par valeurs croissantes :

5	6	6	7	7	8	8	9	111
---	---	---	---	---	---	---	---	-----

Figure I.15 : Principe de fonctionnement du filtre médian.

6.3. Filtres morphologiques

Ce type de filtrage est réalisé par une combinaison de traitement linéaire et non linéaire et il est appliqué à des images binaires, chaque pixel de l'image peut être codé comme un élément logique donc à valeur vraie ou fausse, ainsi il est l'objet d'une transformation par une fonction logique plus ou moins complexe.

Parmi les opérateurs morphologiques (méthodes visant à améliorer les images binaires) nous citons : la dilatation, l'érosion, l'ouverture et la fermeture. [10]

• Dilatation

Elle permet d'éliminer les pixels blancs isolés. On effectue le (ET) logique des huit voisins du pixel considéré.

La dilatation élimine les tâches (les trous) blanches dans les zones noires mais ajoute des pixels noirs au contour des objets présents dans l'image. Donc la taille des objets dans l'image augmente.

$$A \oplus B = B \oplus A = \bigcup_{a \in A} B_a$$

• Erosion

Elle permet d'éliminer les pixels noirs isolés au milieu des parties blanches de l'image, on effectue le OU logique des huit voisins du pixel considéré.

En appliquant une érosion, ces tâches noires peuvent être éliminées mais la taille des objets présents dans l'image diminue car l'érosion enlève des pixels du contour, entraînant une déformation de certains objets

$$A \ominus B = \{z \in E \mid B_z \subseteq A\},$$

• Ouverture

L'ouverture est constituée par une opération d'érosion suivie d'une dilatation. Elle permet de retrouver la taille normale des objets de l'image.

$$A \circ B = (A \ominus B) \oplus B.$$

• Fermeture

La fermeture est l'opération inverse de l'ouverture, qui consiste à faire subir à l'image une dilatation suivie d'une érosion. Elle permet aussi de retrouver la taille normale des objets de l'image.

$$A \bullet B = (A \oplus B) \ominus B.$$

6.4. Filtres Adaptatifs

Lorsque l'on veut filtrer une image, on peut rencontrer deux types de situations : soit la fenêtre d'analyse est située à l'intérieur d'une région, et on a affaire à un signal stationnaire éventuellement perturbé par du bruit à caractère impulsionnel ou continu ; soit elle inclut une transition entre deux régions (contour). L'intérêt des filtres adaptatifs est la possibilité d'ajuster la structure ou les coefficients d'un opérateur à chacune de ces situations. Il s'agit donc de filtres comportant un étage de décision et un étage de filtrage de données. [9]

7. Conclusion :

Dans ce chapitre, nous avons présenté des notions fondamentales ainsi que quelques techniques de traitement d'images, afin de préparer cette dernière à l'analyse. Nous avons présenté quelques traitements qui permettent une amélioration de l'image en vue d'éliminer toutes les imperfections qui existent sur cette dernière, dans le but de parvenir à une analyse plus fine.

Chapitre II

Principes et concepts de base de l'intelligence artificielle



II -1. Introduction

Dans ce chapitre nous aborderons les principes et les concepts de base de l'intelligence artificielle, sa définition, son principe, son utilisation et les domaines d'applications de cette dernière et encore ses avantages, inconvénients et limites.

II -1.1 Principe de l'intelligence artificielle:

L'intelligence artificielle est présente partout, nous nous en servons déjà dans notre vie de tous les jours mais sans s'en rendre compte, que ce soit en utilisant une application de commande vocale, des jeux sur un ordinateur ou encore des outils de domotique. Son principe est de viser à reproduire le fonctionnement du cerveau humain sur les machines, et cela en utilisant un ensemble d'algorithmes d'apprentissage, qui permettent d'apporter à ces machines une sorte d'intelligence

II -1.2 Qu'est-ce que l'intelligence artificielle ?

Les progrès des Neurosciences et l'exploration du cerveau humain soulèvent une question remplie à la fois d'espoir et de crainte: serait-il possible un jour de reproduire l'intégralité du cerveau humain ? Aujourd'hui déjà, les ordinateurs sont supérieurs par rapport au cerveau humain en ce qui concerne la puissance de calcul, bien que le degré de complexité présenté par le cerveau humain soit bien plus élevé. Ces doutes soulèvent la question de l'intelligence artificielle.

Plusieurs définitions ont été attribuées à cette notion parmi elles nous pouvons citer ces deux:

❖ Définition 1

L'intelligence artificielle ou IA est une discipline scientifique et technologique qui vise exécuter par machines (ordinateurs et programmes informatiques) des processus cognitifs réservés aux capacités du cerveau humain, dans les domaines de :

- La compréhension.
- La communication (dialogue entre machines et avec l'humain).
- L'adaptation.
- L'apprentissage en autonomie (Deep Learning). Dans la langue courante, l'IA

Désigne également les dispositifs informatiques ou robotiques mettant en œuvre ces fonctions.

❖ Définition 2

On peut aussi définir l'intelligence artificielle comme étant un ensemble d'algorithmes qui traite un ensemble d'informations ou données, relatives à des tâches, d'une manière similaire ou identique à celle qu'un être humain utilisera pour prendre une décision ou résoudre un problème. Le point commun entre toutes ces définitions se résume dans l'objectif majeur de L'IA qui présente son ambition d'imiter le processus cognitifs de l'être humain.

Ces processus comprennent l'apprentissage (acquisition d'informations et de règles liées à leur utilisation), le raisonnement (application des règles pour parvenir à des conclusions approximatives ou précises) et l'autocorrection. [11] L'IA vise aussi un peu loin et cela afin de mettre au point des systèmes qui résolvent certains problèmes bien mieux que les humains dans le futur

II -2. Les domaines d'applications de L'IA

L'intelligence artificielle, définie comme intelligence présentée par les machines, à de nombreuses applications dans la société d'aujourd'hui. Elle a été utilisée pour développer et faire progresser de nombreux domaines et industries, y compris la santé, le secteur financier et bancaire, le transport, le commerce, l'industrie, l'agriculture intelligente, les médias, le droit...etc.

II -2.1 La santé

C'est l'un des secteurs les plus dynamiques en intelligence artificielle. Aujourd'hui un grand nombre de systèmes se basant sur l'intelligence artificielle commence à diagnostiquer des maladies, notamment les cancers, d'une façon aussi bien voire mieux que les spécialistes. L'intelligence artificielle peut favoriser la détection précoce d'une maladie et aussi pourrait accélérer la mise au point de nouveaux médicaments et réduire le temps écoulé entre ladé couverte d'une nouvelle molécule et sa mise sur le marché [12].

II -2.2 Le transport Les voitures d'aujourd'hui ont des fonctions d'aide à la conduite basées sur l'IA telles que le stationnement automatique. L'intelligence artificielle a été utilisée dans ce domaine afin de pouvoir optimiser les applications de gestion du trafic, ce qui permet de réduire les temps d'attente, la consommation d'énergie et les émissions. Cette utilisation devrait fournir aussi un transport sûr, efficace et fiable tout en essayant de minimiser l'impact sur l'environnement. À l'avenir, des voitures entièrement autonomes sont envisagées à être développées.

II -2.3 Le commerce

L'intelligence artificielle a un impact énorme sur le commerce. Aujourd'hui, les robots effectuent plusieurs tâches d'aide, par exemple la vérification de l'inventaire, la surveillance des planchers qui sont sales et les nettoyer, faire le suivi des étiquettes de prix, le travail à la caisse et beaucoup plus.

Toutes ces tâches sont réalisées par des machines afin de faire face aux défis de la main-d'œuvre que les supermarchés rencontrent comme difficultés.

II -2.4 L'agriculture intelligente

Dans le domaine agricole, le déploiement de l'IA se fait de plusieurs manières, D'abord, elle aide les agriculteurs à surveiller leurs champs et ça grâce à l'utilisation des capteurs, ensuite à l'aide des techniques d'apprentissage automatique et le Deep Learning, une analyse très précise est faite sur ces informations captées. Par exemple, dans le cas de La reconnaissance d'images de plantes, les techniques d'IA aident à détecter certains défauts comme la présence de ravageurs sur les feuilles.

On peut aussi trouver d'autres applications de l'IA dans l'agriculture comme l'augmentation des rendements. Ceux-ci s'appuient sur des paramètres comme le climat, l'état des semences et des sols, les niveaux d'irrigation etc., pour aider les agriculteurs à savoir quoi planter, où et quand, quels plants surveiller et quand récolter.

II -2.5 Le droit

L'intelligence artificielle intervient aussi dans le domaine de droit. Elle fournit un ensemble d'algorithmes qui sont susceptibles d'analyser une jurisprudence afin de déterminer les arguments clés, fournir un conseil juridique sur la qualité d'un contrat ou la probabilité de gagner un contentieux et même d'estimer le montant des indemnités à espérer [13]

II- 3. Apprentissage Profond (Deep Learning)

II -3.1 Définition et origines

Le Deep Learning ou apprentissage profond est un type d'intelligence artificielle, dérivé du machine Learning qui a été développé dans le but de créer des algorithmes capables d'apprendre et de s'améliorer de manière autonome, contrairement à la programmation où la machine se contente d'exécuter à la lettre des règles prédéterminées. L'apprentissage en profondeur utilise une succession de couches d'unités de traitement non linéaire pour pouvoir extraire ou transformer les caractéristiques des données.

La sortie d'une couche sert d'entrée de la couche suivante. Les algorithmes de l'apprentissage profond peuvent être supervisés et servir à classer les données, ou non supervisés et aider à effectuer une analyse de modèle. L'algorithme de Deep Learning absorbe des quantités de données énormes par rapport aux autres algorithmes d'apprentissages machine utilisés et développés actuellement, et il a été capable de battre les humains dans certaines tâches cognitives. Par exemple, la reconnaissance faciale par ordinateur et la reconnaissance vocale ont connu des Progrès significatifs et cela grâce aux approches d'apprentissage approfondies.

Parmi ces approches d'apprentissage approfondies, on compte les réseaux de neurones artificiels sur lesquels reposent le Deep Learning et ainsi certaines technologies comme la reconnaissance d'image ou la vision robotique. Les réseaux de neurones artificiels sont inspirés par les neurones du cerveau humain. Ils sont constitués à base de plusieurs neurones artificiels connectés entre eux. Plus le nombre de neurones est considérable, plus le réseau est profond




Figure 3.1: La relation entre l'IA, Machine Learning et Deep Learning

II-4. Les réseaux de neurones artificiels

II -4.1 Définition

Un réseau de neurones artificiels, ou (Artificial Neural Network en anglais), est un système informatique matériel et / ou logiciel s'inspirant du fonctionnement du cerveau humain pour apprendre. Il s'agit d'une variété de technologie Deep Learning, qui fait elle-même partie de la sous-catégorie d'intelligence artificielle et du Machine Learning. Ce genre de réseau est défini par un ensemble de couches de neurones qui sont fortement inter connectées entre elles.

II -4.2 Architecture d'un réseau de neurones artificiel

En général un réseau de neurones est constitué d'un ensemble de couches successives dont chacune prend ses entrées sur les sorties de la précédente c.-à-d. que cet ensemble est entièrement connecté. Chaque couche est un ensemble de neurones n'ayant pas de connexion entre eux et qui reçoivent des informations numériques en provenance de neurones voisins. L'ensemble de couches est composé d'une couche d'entrée qui lit les valeurs d'entrées, une couche de sortie qui fournit les résultats du système et entre ces deux se cacheuse à plusieurs couches dites cachées qui participent au transfert. Comme le montre la figure 2.2 suivante.

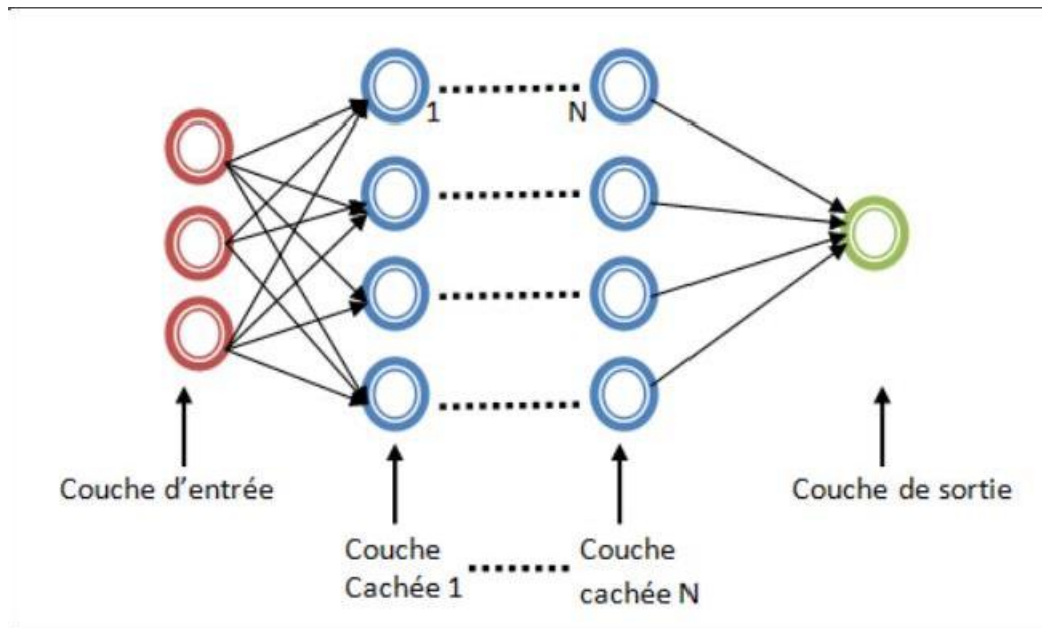


Figure 4.2 : Architecture de base d'un réseau de neurones artificiel

II -4.3 Principe de fonctionnement d'un réseau de neurones artificiel

Définissons maintenant le principe de fonctionnement d'un réseau de neurone en représentant les grandes étapes réalisées lors l'utilisation de ce réseau

- On attribue à chaque neurone constituant le réseau un coefficient qu'on appelle poids.
- Chaque donnée d'entrée (input) va être multipliée par ce coefficient et on va applique une fonction d'addition à l'ensemble des résultats. Cette fonction est appelée fonction de combinaison.
- Puis on va appliquer une fonction d'activation, en comparant la somme obtenue à un seuil déterminé.

Si la somme est en dessous du seuil (souvent dans le cas où la somme est négative), le neurone ne s'active pas, ce qui signifie que la donnée n'est pas intéressante.

Si cette somme est au-dessus du seuil (souvent dans le cas où la somme est positive), alors le neurone s'active et envoie l'information au neurone de la couche suivante (couches cachées), jusqu'à ce que la donnée ultime atteigne le dernier neurone. On aura alors un résultat final (output). Ce principe est illustré dans la figure 2.3 suivante.

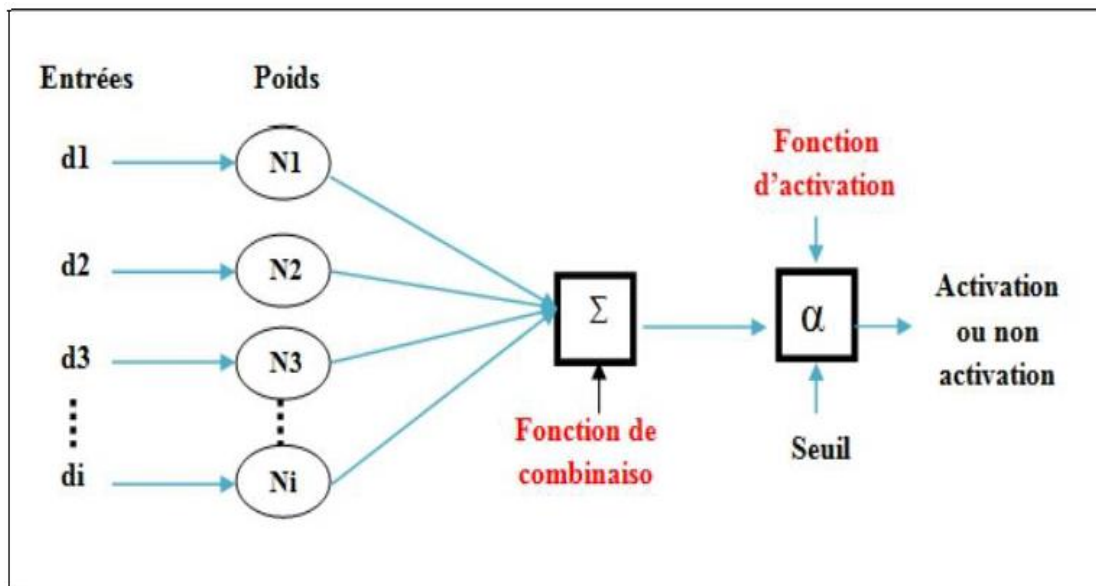


Figure 4.3: Principe de fonctionnement d'un réseau de neurones artificiel

II -4.5 Types des réseaux de neurones

Il existe différents types de réseaux de neurones, et ils sont classés en fonction du nombre de nœuds cachés du modèle ou encore du nombre d'entrées et de sorties de chaque nœud.

La propagation des informations entre les différents neurones peut varier et dépend du type de réseaux de neurones.

- Les réseaux de neurones dit "feed-forward" (à propagation avant): c'est la variante la plus simple, l'information ne se déplace que dans une seule direction, elle traverse directement l'entrée aux nœuds de traitement (couches cachées) puis aux sorties, avec absence de cycle ou de boucle dans le réseau.

- Les réseaux de neurones récurrents: Ce mode d'apprentissage est un peu plus complexes, ils comportent au moins un cycle dans leurs structures, ils sauvegardent les résultats produits par les nœuds de traitement et nourrissent le modèle à l'aide de ces résultats. Parmi ses applications, on trouve: la reconnaissance automatique de formes, la traduction automatique de la parole...etc.
- Les réseaux de neurones convolutifs : leur fonctionnement est inspiré par un processus biologique qui est le cortex visuel des animaux, les données à traiter traversent une multitude de couches (de la couche d'entrée vers la couche de sortie).

Ce type de réseaux s'applique dans différents domaines: la reconnaissance faciale, la reconnaissance d'images et vidéos, le traitement du langage naturel ...etc. [14]

Exemples du Deep Learning

On va étudier un exemple concret de la reconnaissance d'images, à l'aide des réseaux de neurones, et qui consiste à reconnaître les photos d'un chat afin d'illustrer cette notion. Tout d'abord, le réseau de neurones prend en entrée un ensemble d'images de chats différents mélangés avec des objets qui ne sont pas des chats, puis il va effectuer une analyse de chaque image afin de s'entraîner pour pratiquer le Deep Learning. Ces images sont ensuite converties en données et transférées sur le réseau. Ensuite les neurones artificiels s'attribuent un poids aux différents éléments. Enfin la couche finale de neurones va rassembler les différentes informations pour déduire le résultat s'il s'agit d'une image d'un chat ou non.

Le réseau de neurones va ensuite effectuer une comparaison entre cette réponse et les bonnes réponses proposées par les humains.

Si les réponses sont pareilles, le réseau garde cette réussite en mémoire et s'en servira plus tard pour reconnaître les chats. Dans le cas contraire, le réseau ajuste le poids placé sur les différents neurones afin de corriger son erreur.

Ce processus représenté dans la Figure 3.2 est répété des milliers de fois jusqu'à ce que le réseau arrive à reconnaître un chat sur une photo dans toutes les circonstances. [15]




Figure 4.5: le processus d'auto-apprentissage pour l'identification d'un chat

II-5. Les réseaux de neurones convolutifs (CNN : Convolutional neural networks)

L'apprentissage en profondeur est l'une des techniques d'apprentissage automatique les plus largement utilisées qui a remporté un énorme succès dans des applications telles que la détection d'anomalies, la reconnaissance d'images, la reconnaissance de formes et le traitement du langage naturel.

Les architectures de Deep learning se varient selon ces applications, on trouve alors trois catégories principales de réseaux de neurones, à savoir,

- Les réseaux de neurones convolutifs (la reconnaissance d'images).
- Les réseaux non surveillés pré-entraînés (la détection d'anomalies).
- Les réseaux de neurones récurrents / récurrents (le traitement du langage naturel, la synthèse vocale et la traduction automatique.).

Les progrès de l'IA et de l'apprentissage profond ont permis une évolution rapide dans les domaines de la vision par ordinateur et de l'analyse d'images. Tout cela est rendu possible par l'émergence et les progrès des réseaux de neurones convolutionnels.

II -5.1 Définition d'un réseau neuronal convolutif

Un réseau neuronal convolutif est un algorithme d'apprentissage en profondeur qui peut reconnaître et classer les caractéristiques des images pour la vision par ordinateur. ILS 'agit d'un réseau neuronal multicouche conçu pour analyser les entrées visuelles et effectuer des tâches telles que la classification d'images, la segmentation et la détection d'objets. [16]

II -5.2 Architecture et fonctionnement d'un CNN

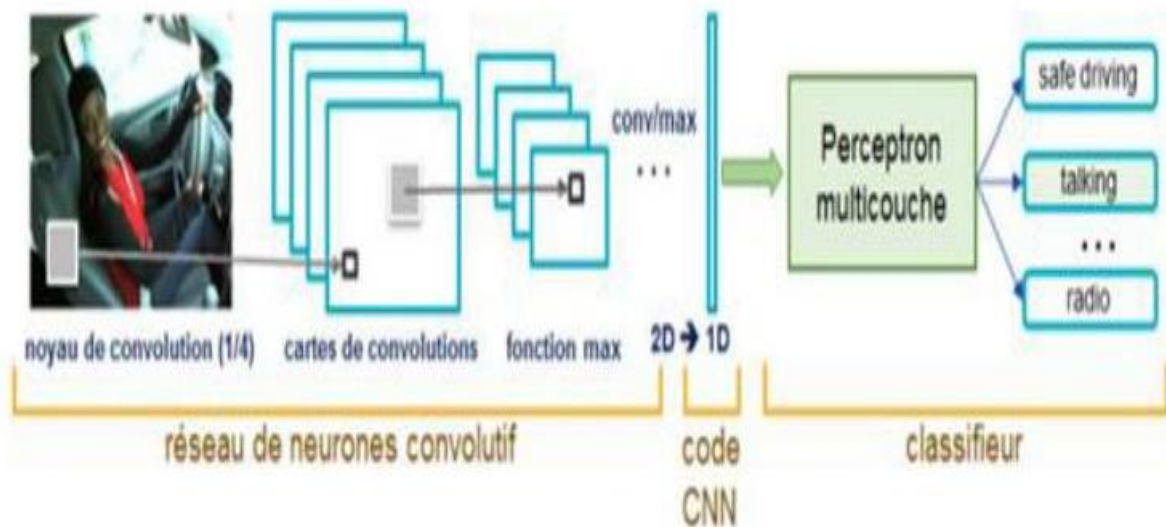


Figure 5.2: Architecture de base d'un réseau neuronal convolutif

L'architecture de CNN est inspirée par l'organisation et la fonctionnalité du cortex visuel et conçue pour imiter le modèle de connectivité des neurones dans le cerveau humain. [17]

Les réseaux de neurones convolutifs sont à ce jour les modèles les plus performants pour classer des images. Ils comportent deux parties bien distinctes: la partie convolutive et la partie classification.

II -5.3 Partie convolution

Son rôle est d'extraire les caractéristiques des images. Une succession de filtres est appliquée à l'image d'entrée, pour produire de nouvelles images en sortie appelées cartes de convolutions. Certains filtres utilisent l'opération de maximum local (Pooling) pour redimensionner l'image en réduisant sa dimension, tout en préservant sa caractéristique importante. Finalement les cartes de convolutions sont chaînées dans un vecteur de caractéristiques appelé code CNN.

Dans la partie convolution on distingue 3 types de couches :

- Les couches de convolutions
- Les couches de correction ReLU
- Les couches de Pooling

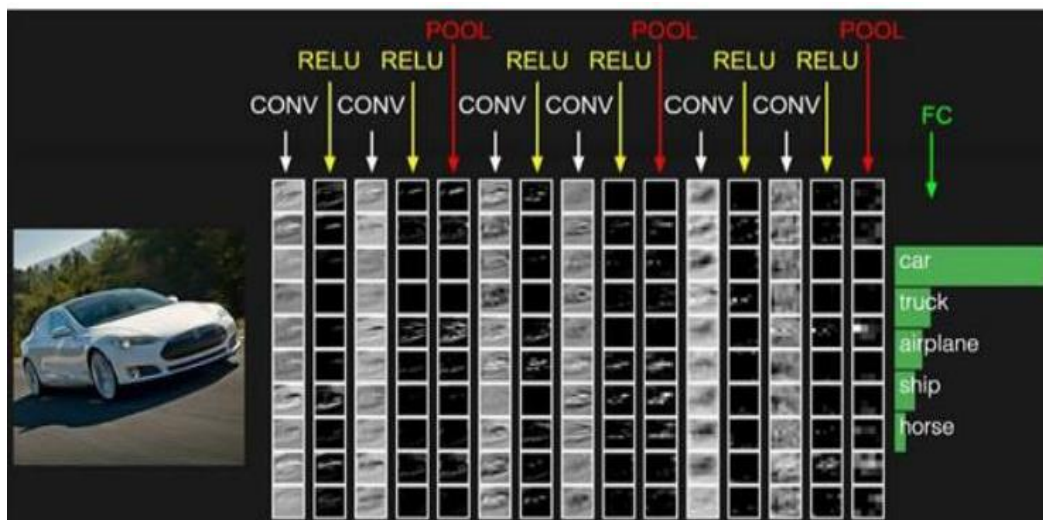


Figure 5.3: La partie convolution d'un CNN

II -5.3.1 Couche de convolution

Notion de convolution




Figure 5.3.1.1 : Parcours de la fenêtre de filtre sur l'image

La convolution est une opération mathématique simple généralement utilisée pour le traitement et la reconnaissance d'images. Sur une image, son effet s'assimile à un filtrage dont voici le fonctionnement [19]

1. Dans un premier temps, on définit la taille de la fenêtre de filtre située en haut agache.
2. La fenêtre de filtre, représentant la facture, se déplace progressivement de lagauche vers la droite d'un certain nombre de cases défini au préalable (le pas)jusqu'à arriver au bout de l'image.

3. À chaque portion d'image rencontrée, un calcul de convolution s'effectue permettant d'obtenir en sortie une carte d'activation ou featuremap qui indique où sont localisées les factures (les caractéristiques) dans l'image : plus la featuremap est élevée, plus la portion de l'image balayée ressemble à la featur

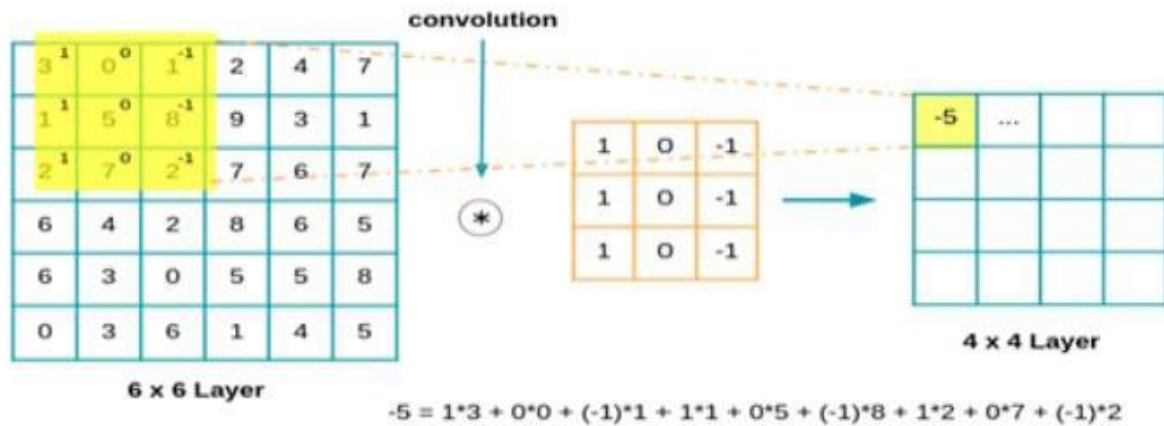


Figure 5.3.1.1: Le principe de convolution

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

Pour chaque paire (image, filtre), une carte d'activation ou featuremap, lui est associée et qui sert à indiquer où se trouvent les features dans l'image : plus la valeur est élevée, plus l'endroit correspondant dans l'image ressemble à la feature.

II -5.3.2 Couches de correction (RELU)

Il est possible d'améliorer l'efficacité du traitement en insérant entre les couches de traitement une couche qui va appliquer une fonction mathématique (fonction d'activation) sur les signaux de sortie [11]

On fait passer les cartes de convolutions à travers une couche d'activation non linéaire telle que Rectified Linear Unit (ReLU), qui consiste à remplacer les nombres négatifs des images filtrées par des zéros.[20]



Figure 5.3.2: Fonctionnement de la fonction RELU

II -5.3.3 Couche Pooling (ou sous-échantillonnage)

Ce type de couche est souvent placé entre deux couches de convolution, elle consiste à un ré-échantillonnage des données; elle prend plusieurs feature map en entrée et applique à chacune d'entre elle la fonction de Pooling, qui permet de réduire la taille des images en conservant leurs caractéristiques importantes.

Pour cela, l'image est découpée en plusieurs cellules régulières. Puis dans chaque cellule on garde la valeur maximale. Généralement, on utilise des cellules carrées, de petites tailles pour ne pas perdre beaucoup d'informations.




Figure 5.3.3: Le principe de Pooling avec un filtre 2*2 et un pas de 2 [22]

A la sortie de cette couche, on obtient en le même nombre de feature maps qu'en entrée, mais cette fois de taille réduite.

La couche de Pooling est utilisée pour minimiser le nombre de calculs et de paramètres dans le réseau. Afin de pouvoir contrôler l'over fitting (sur-apprentissage) et ainsi améliorer l'efficacité du réseau, une couche de Pooling est fréquemment insérée périodiquement entre deux couches de convolution successives.

A la fin du réseau, pour pouvoir indiquer la probabilité qu'une entité spécifique appartient à une certaine classe, un MLP (Multi Layer perceptron) souvent appelé Fully-Connected est ajouté.

II -5.4 Partie classification

Elle est constituée de couches entièrement connectées (perceptron multicouche). Elle prend la sortie de la partie convolutive qui est le code CNN comme entrée, afin de combiner ses caractéristiques pour classer l'image.

II -5.4.1 Couche Fully-connected (entièrement connecté)

Elle constitue toujours la dernière couche d'un réseau de neurones convolutif ou non. Elle reçoit un vecteur en entrée contenant les pixels aplatis de toutes les images filtrées, La dernière couche Fully-connected permet de classifier l'image en entrée du réseau : elle renvoie un vecteur de taille N, où N est le nombre de classes dans notre problème de classification d'images. Chaque élément du vecteur indique la probabilité pour l'image en entrée d'appartenir à une classe. [21].

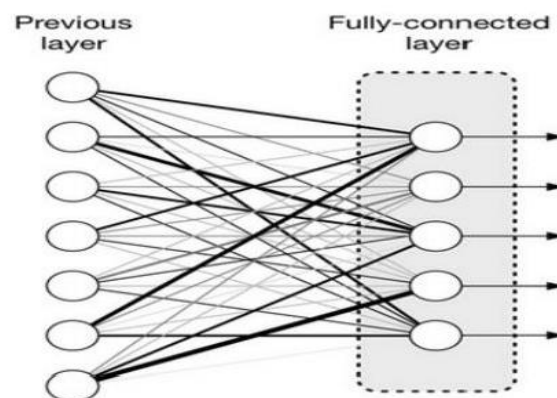


Figure 5.4.1.1: La couche Fully connected

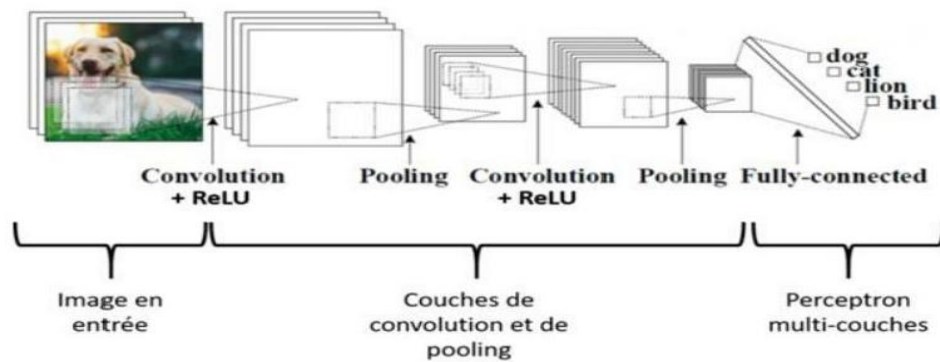


Figure 5.4.1.2: Le fonctionnement d'un réseau de neurones à convolution [23]

II-6. Modèles CNN prédéfinis

II -6.1 LeNet

LeNet Est proposé par l'inventeur Yann Le Cun en 1998 .Ce réseau était dédié à la reconnaissance des photos noir et blanc et de chiffres. Il est composé uniquement de quelques couches et peu de filtres, en raison des limitations de l'ordinateur à cette époque. Il s'agit d'un petit réseau qui contient les modules de base du Deep Learning. L'architecture CNN de Le Net est composée de sept couches dont trois sont des couches convolutives, deux sont des couches de sous-échantillonnage et deux sont des couches entièrement connectées.




Figure 6.1: Visualisation de l'Architecture du réseau LeNet-5 [24]

II -6.2 AlexNet

AlexNet a été retenu dans ILSVRC 2012 , Il résout le problème de la classification des images où l'entrée est une image de l'une des 1000 classes différentes (par exemple, chats, chiens, etc.) et la sortie est un vecteur de 1000 éléments. [25]

AlexNet contient 5 couches convolutives et 3 couches entièrement connectées. La couche Relu est appliquée après les couches de convolution et entièrement connectée. La couche dropout est appliquée avant la première et deuxième couches entièrement connectées.




Figure 6.2: Visualisation de l'architecture du réseau AlexNet

II -6.3 VGG16

VGG Est une architecture de réseau de neurones populaire qui est également basée sur les CNN, a été appliquée au Défi Image Net en 2014. Le réseau a atteint une précision de test de 92,7% dans le top 5 sur l'ensemble de données Image Net. Les principales améliorations de VGG, par rapport à Alex Net, incluent l'utilisation de grands filtres de la taille d'un noyau. VGG Net se compose de 16 couches convolutives. [24]




Figure 6.3 : Visualisation de l'architecture du réseau VGG16.

II -6.4 GoogleNet

GoogleNet est le lauréat de l'ILSVRC 2014, avec un taux d'erreur de 6,67% dans le top 5. Le réseau utilise un réseau CNN inspiré par LeNet. La principale caractéristique de cette architecture est la meilleure utilisation des ressources informatiques à l'intérieur du réseau. Ceci a été réalisé grâce à une conception soigneusement conçue qui permet d'augmenter la profondeur et la largeur du réseau tout en maintenant le budget de calcul constant. [27]

L'architecture de GoogleNet consistait en un réseau CNN profond de 22 couches mais réduisait le nombre de paramètres de 60 millions (AlexNet) à 4 millions

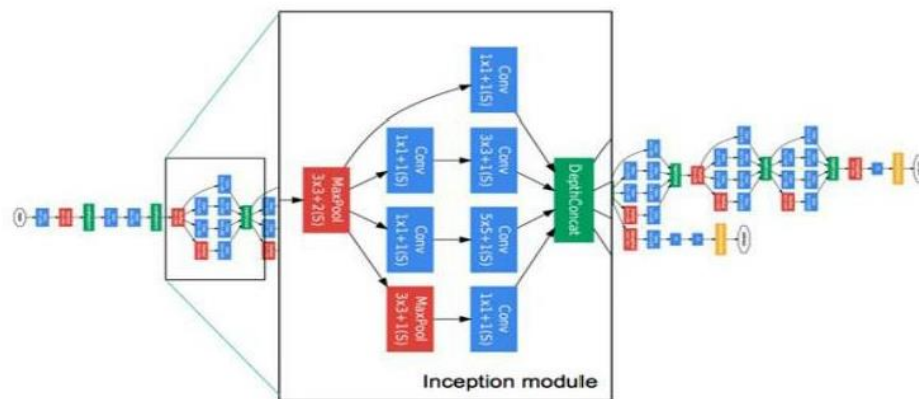


Figure 6.4.1: Visualisation de l'architecture du réseau GoogleNet (1).




Figure 6.4.2 : Visualisation de l'architecture du réseau GoogleNet (2).

II -6.5 ResNet

C'est l'un des réseaux de neurones profonds les plus puissants qui a obtenu des résultats de performances fantastiques dans le défi de classification ILSVRC 2015.

ResNet a réalisé d'excellentes performances de généralisation sur d'autres tâches de reconnaissance et a remporté la première place sur la détection ImageNet, la localisation ImageNet, la détection COCO et la segmentation COCO dans les concours ILSVRC et COCO 2015.

Il existe de nombreuses variantes de l'architecture ResNet, c'est-à-dire le même concept mais avec un nombre de couches différent. Nous avons ResNet-18, ResNet-34, ResNet-50, ResNet-101, ResNet-110, ResNet-152, ResNet-164, ResNet-1202.




Figure 6.5: Visualisation de l'architecture du réseau ResNet.

II -7. Conclusion

Nous avons consacré ce chapitre à la présentation des notions de classification d'images et de ses différentes caractéristiques, et domaines d'application, ainsi qu'à l'utilisation de la machine Learning et du Deep Learning dans ce domaine. Nous avons également abordé la notion des réseaux de neurones convolutifs, plus précisément, nous avons donné sa définition, son architecture et son principe de fonctionnement où nous avons cité les différentes couches qui constituent ce réseau. Enfin, nous avons présenté les différents modèles prédéfinis du CNN, tout en détaillant chaque modèle (LeNet, AlexNet, VGG, GoogleNet et ResNet).

Chapitre III

Résultats et discussion

1. Introduction

Le présent chapitre est constitué de trois parties, la première partie consiste à expliquer les différentes étapes à suivre pour faire la classification d'une image de cerveau, ensuite on présente dans la deuxième partie les résultats obtenus et les diverses discussions et les solutions proposées pour certains problèmes rencontrés, enfin la conclusion de ce chapitre est développée dans la troisième partie.

2. Les Outils logiciels utilisés

Afin de réaliser notre implémentation et de pouvoir classer l'ensemble des images de cerveau, nous avons utilisé deux outils logiciels qui sont Matlab et python.

3. Définition de Matlab

MATLAB est à la fois un langage de programmation et un environnement pour faire du calcul numérique, il permet de faire plusieurs tâches telles que: des manipulations sur des matrices, le traçage des fonctions, la visualisation de données, le traitement d'images, l'implémentation de nouveaux algorithmes, et faire des interfaces graphiques...etc.

MATLAB contient une multitude de boîtes à outils (toolbox) spécifiques à des domaines variés. Elles constituent un ensemble de fonctions spécifiques à un domaine d'application.


On peut citer:

- Résolution d'équations aux dérivées partielles
- Optimisation
- Traitement du signal
- Traitement de l'image
- Classification d'images
- Logique floue
- Réseaux de neurones
- ...etc.


Dans notre cas on a utilisé la boîte à outils spécifique au domaine de classification d'images, qui offre différents packages qui permettent l'implémentation des modèles d'apprentissage Alexnet et GoogleNet sous Matlab.

4. Dataset

Dans notre projet de fin d'étude nous avons utilisé la base de données provient du site Web[28]. Cette base de données contient des images IRM de tumeurs cérébrales d'un groupe de personnes en bonne santé et d'autres malades. Il y en a deux dossiers l'un représente les images normales du cerveau et l'autre représente les images de la tumeur. Au total il y a 2065 images dans ces deux dossiers (voir Figure III.1).



En bonne santé



Malades

Figure III.1 : Images par résonance magnétique du cerveau d'une personne en bonne santé et d'autre malades.

Les images doivent être redimensionnées pour correspondre à la dimension spécifiée dans la couche d'entrée de chaque réseau(image Input Layer).

5. Architectures et paramètres des modèles CNNs utilisés dans l'implémentation

Au cours de notre travail et afin de pouvoir réaliser la classification automatique de l'ensemble d'images, nous avons adopté deux modèles CNNs à savoir AlexNet et GoogleNet. Ces deux réseaux pré-entraînés sont conçus pour résoudre le problème de la classification des images où l'entrée est une image de l'une des 1000 classes différentes et la sortie est un vecteur de 1000 éléments. Donc leurs 3 dernières couches sont configurées pour 1000 classes.

Dans notre cas nous travaillons sur 2 classes, donc pour utiliser ces réseaux, nous les avons adaptés à notre nouveau cas en utilisant la méthode de transfert learning. [1]

6. Transfert learning

Le transfert learning est une technique développée dans le domaine de l'apprentissage automatique qui consiste à enregistrer les informations acquises en essayant de résoudre un problème particulier dans le but de les utiliser pour résoudre un autre problème similaire. Par exemple, les informations obtenues lors de l'identification d'images d'oiseaux peuvent être utilisées pour tenter d'identifier des images d'aéronefs. Comme autre exemple, les informations obtenues lors de l'identification des voitures peuvent être utilisées pour identifier d'autres objets similaires tels que des camions.

- *Comment le transfert learning bénéficie des réseaux préformés:*

Plusieurs groupes de logiciels ont construit plusieurs modèles de réseaux de neurones pour la reconnaissance d'images. Ces modèles sont constitués d'un grand nombre de couches cachées complexes dans leur structure. Ces modèles ont été entraînés sur un très grand nombre d'images, estimé à plusieurs millions. Ces modèles ont montré une très grande capacité à identifier un grand nombre d'objets. Ces modèles intelligents peuvent être réutilisés pour identifier de nouveaux objets non formés auparavant. Cela se fait en enlevant la dernière couche et en la remplaçant par de nouvelles couches et en la rééduquant dans le but de la préparer à reconnaître de nouveaux organismes. Ce processus est appelé « apprentissage par transfert » ou *Transfert learning*.

7. Architecture d'AlexNet et de GoogleNet

- *AlexNet*

Nous avons gardé toutes les couches des réseaux telle quelles à l'exception des trois dernières. Ces trois couches doivent être adaptées pour le nouveau problème de classification. Alors ces trois dernières on les a remplacées par une couche entièrement connectée, une couche softmax et une couche de sortie de classification. Nous avons spécifié les options de la nouvelle couche entièrement connectée en fonction des nouvelles données en la définissant pour qu'elle ait la même taille que le nombre de classes dans la nouvelle situation, alors nous l'avons configuré pour 2 classes. Comme il est mentionné dans la partie du code suivante : .[1]

```
net=alexnet;
% extraire les couche du reseau sauf les 3 dernieres
layersTransfer = net.Layers(1:end-3);

% nombre de classes
numClasses = numel(categories(imdsTrain.Labels));
% Nouvelle couche
layers = [
layersTransfer
fullyConnectedLayer(numClasses, 'WeightLearnRateFactor',20, 'BiasLearnRateFactor',20)
softmaxLayer
classificationLayer];
```

- *GoogleNet*

Le rôle des couches convolutives du réseau est d'extraire des caractéristiques d'image que la dernière couche apprenable et la couche de classification finale utilisent pour classer l'image d'entrée. Dans GoogleNet les deux couches, 'loss3-classifier' et 'output', contiennent des informations sur la manière de combiner les fonctionnalités extraites par le réseau en probabilités de classe, valeur de perte et étiquettes prédites. Afin d'adapter ce réseau à l'ensemble d'images, nous avons remplacé ces deux couches par de nouvelles couches adaptées à cet ensemble, comme il est mentionné dans la partie du code suivante. [1]

```
net=googlenet;
lgraph = layerGraph(net);

% Number of categories
numClasses = numel(categories(imdsTrain.Labels));

% New Learnable Layer

newFCLayer = fullyConnectedLayer(numClasses, 'Name', 'new_fc', 'WeightLearnRateFactor',10, 'BiasLearnR
lgraph = replaceLayer(lgraph, 'loss3-classifier', newFCLayer);
newClassLayer = classificationLayer('Name', 'new_classoutput');
lgraph = replaceLayer(lgraph, 'output', newClassLayer);
```

8. Les paramètres d'AlexNet et de GoogleNet

Le tableau III.1 représente les différents paramètres des modèles de CNNs utilisés dans le cadre de ce mémoire à savoir AlexNet et GoogleNet. [1]

Modèle \ Paramètres	Epoch	Input images sizes	Learning rate
AlexNet	10	227	1e-4
GoogleNet	10	224	1e-4

Tableau III.1 : Tableau représentant les paramètres des modèles AlexNet et GoogleNet.

- **Epoch**: Le nombre d'époques est un hyper paramètre qui définit le nombre de fois où l'algorithme d'apprentissage fonctionnera sur l'ensemble des données d'apprentissage.
- **Input images sizes**: c'est la taille des images entrées. Ces tailles diffèrent d'un modèle à un autre.
- **Learning rate**: ou taux d'apprentissage en français. Dans le domaine de l'apprentissage automatique, le taux d'apprentissage consiste à un paramètre de réglage, qui détermine la taille du pas à chaque itération tout en visant le minimum d'une fonction de perte. Il représente métaphoriquement la vitesse à laquelle un modèle d'apprentissage automatique apprend.
- **Les indicateurs de performance**

Dans le but d'évaluer les performances des deux modèles (AlexNet et GoogleNet) que nous allons utiliser pour l'implémentation, nous allons calculer la précision (Accuracy), qui est le nombre total de prédictions correctes divisé par le nombre total de prédictions effectuées pour un ensemble de données. [1]

9. Résultats et Discussion

Les algorithmes du Deep learning raffolent aujourd'hui de gros volumes d'images labellisés, et pour améliorer leurs performances on utilise la technique de *Data Augmentation*, qui consiste à faire subir des transformations à l'ensemble des images avant de les utiliser pour l'entraînement, tout en conservant leur structure. Pour chaque observation, on crée plusieurs variations. Ces transformations peuvent être classées en deux catégories: un

ensemble de transformations affines comme le flip horizontal et/ou vertical, la rotation ou non affines comme la variation de luminosité et de contraste, le redimensionnement...etc. Ainsi le volume de données est artificiellement multiplié.

Comme un processus de formation (Training), nous avons formé AlexNet et GoogleNet avec la technique d'augmentation des données.

La figure III.1 représente les courbes la précision et la perte d'entraînement du modèle AlexNet avec la technique d'augmentation des données avec un nombre d'epochs égal à 10. D'après cette figure nous pouvons observer que la précision d'apprentissage est en train d'augmenter pour atteindre 98% après 10 epochs, tandis que la perte diminue au fur et à mesure.



Figure III.1 : Progression de l'apprentissage du réseau AlexNet avec augmentation des données.

La figure III.2 représente les résultats obtenus, dans quelque image de test, par l'utilisation du modèle AlexNet:

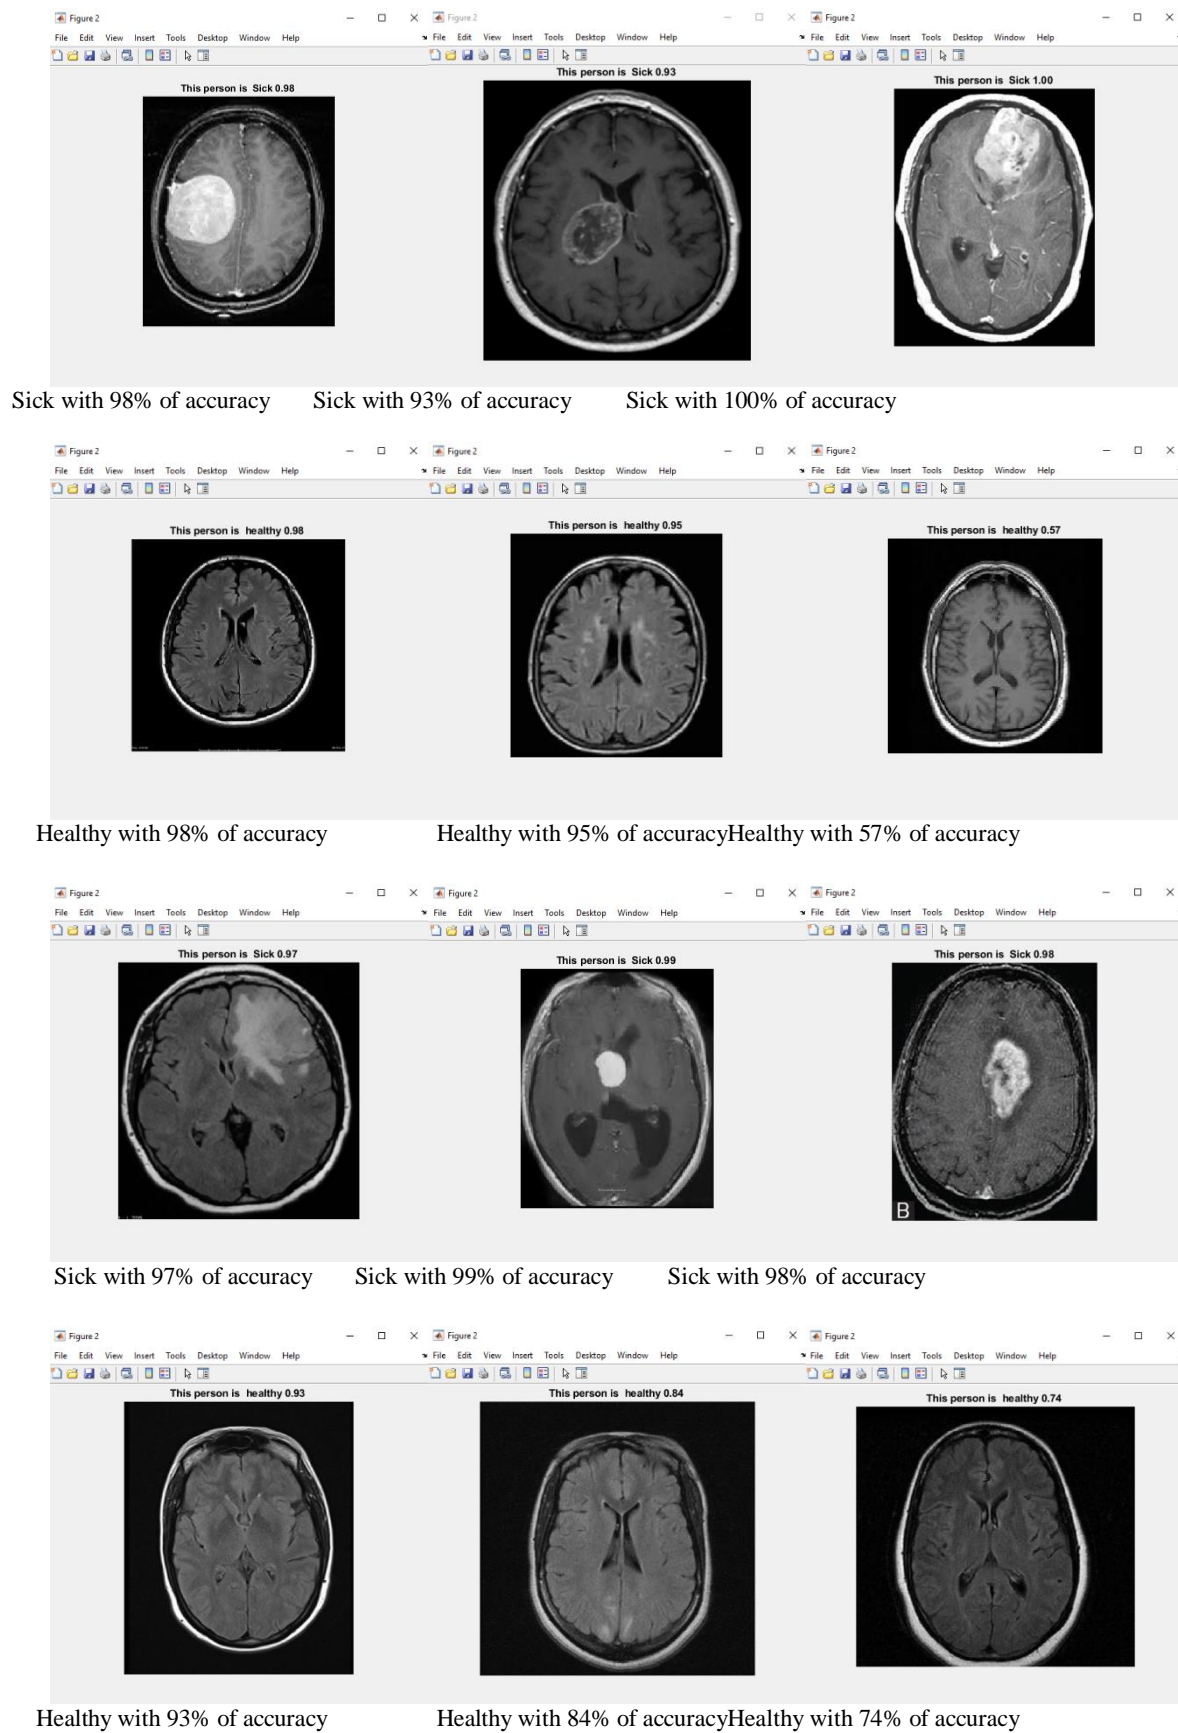


Figure III.2 : Résultats obtenus, dans quelque image de test, par l'utilisation du modèle AlexNet.

Le tableau III.2 représente l'accuracy obtenue dans l'ensemble d'images d'apprentissage et de test, en utilisons le modèle AlexNet:

	Training Dataset	TestingDataset
Accuracy (%)	98	97.67

Tableau III.2: Accuracy obtenue dans l'ensemble d'images d'apprentissage et de test, en utilisons le modèle AlexNet.

La figure III.3 Représente la courbe de précision et de perte d'entraînement de GoogleNet avec augmentation de données. D'après cette figure nous pouvons observer que la précision d'apprentissage augmente à travers les epochs, tandis que la perte diminue au fur et à mesure.

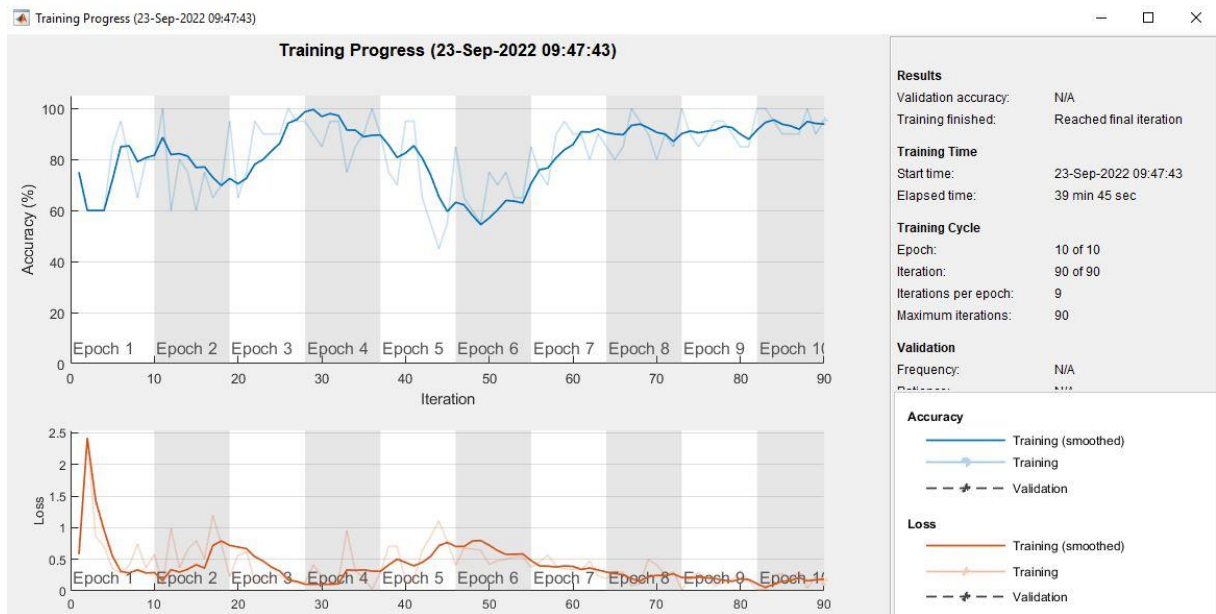


Figure III.3: Progression de l'apprentissage du réseau GoogleNet avec augmentation des données.

La figure III.4 représente les résultats obtenus, dans quelque image de test, par l'utilisation du modèle GoogleNet:

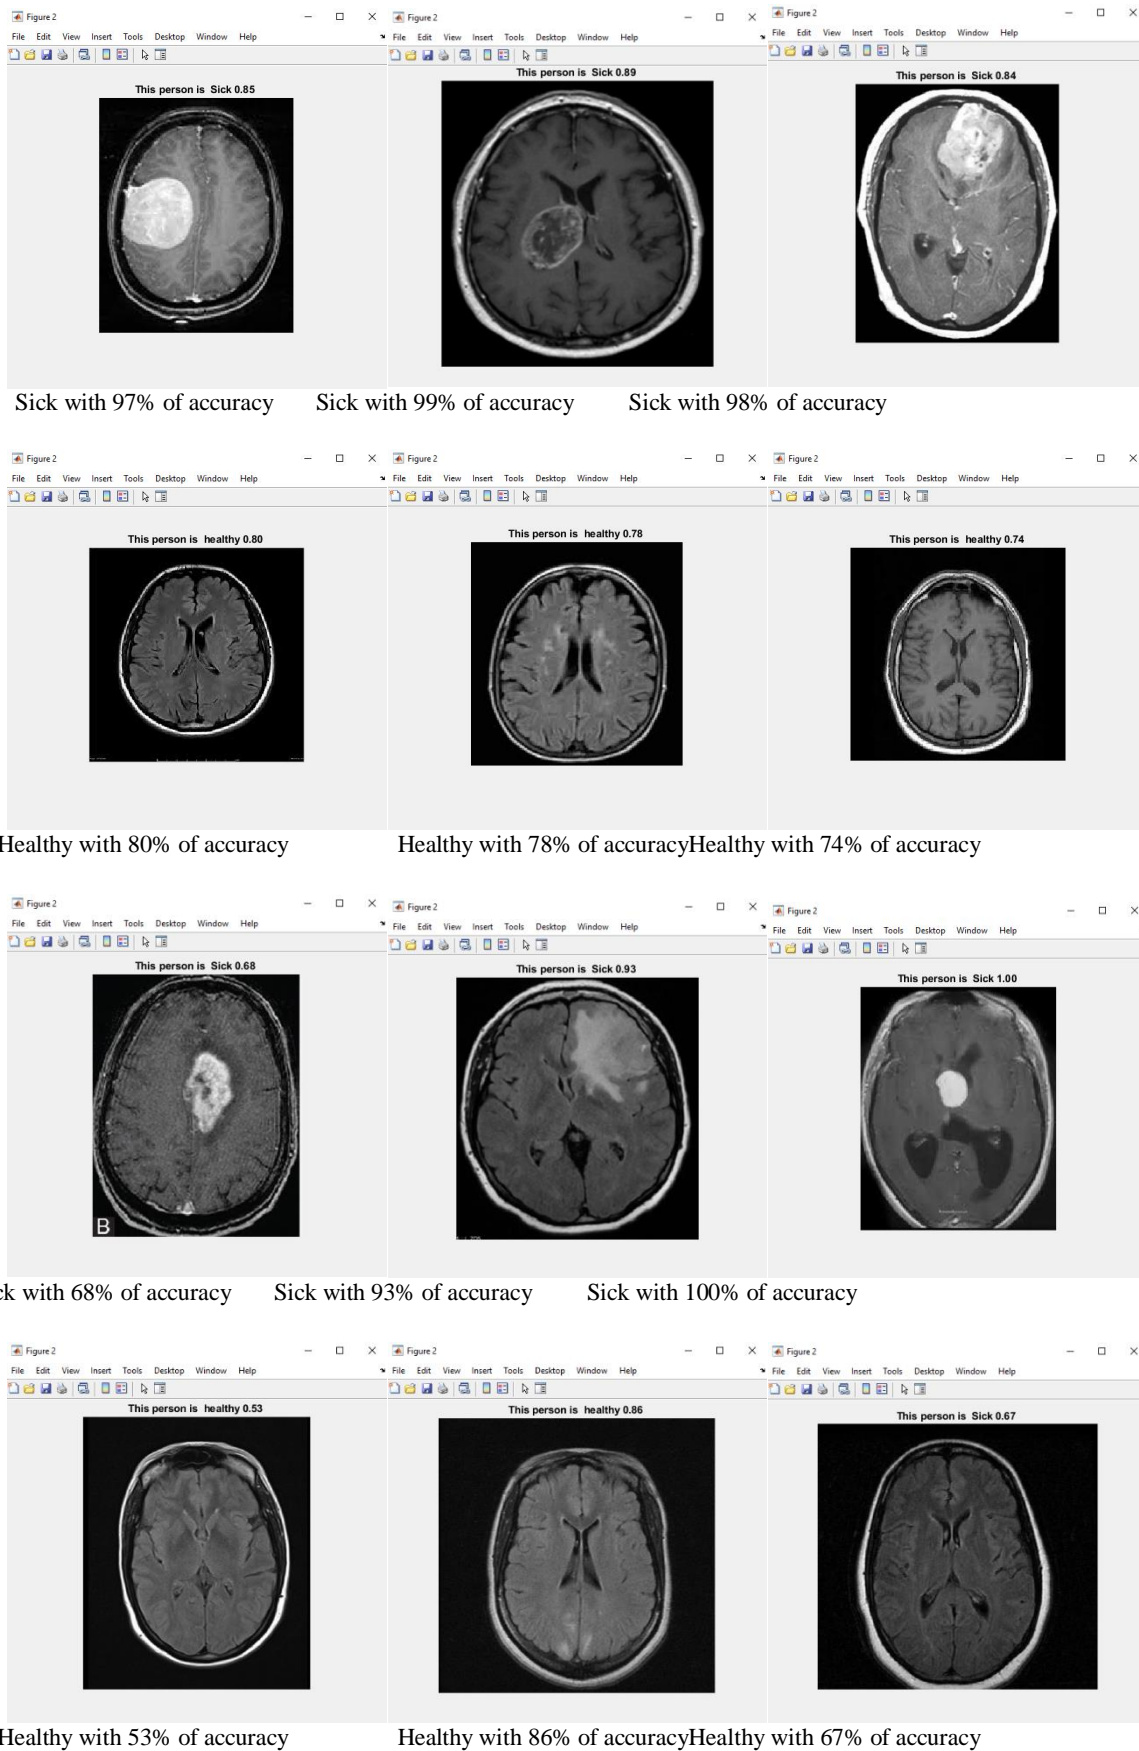


Figure III.3 : Résultats obtenus, dans quelque image de test, par l'utilisation du modèle GoogleNet.

Le tableau III.3 représente l'accuracy obtenue dans l'ensemble d'images d'apprentissage et de test, en utilisons le modèle GoogleNet:

	Training Dataset	TestingDataset
Accuracy (%)	99	81.40

Tableau III.3 : Accuracy obtenue dans l'ensemble d'images d'apprentissage et de test, en utilisons le modèle GoogleNet.

Comme on le voit dans Les figures III.1, III.2 et III.3 et les tableaux III.2 et III.3, on peut conclure que les deux modèles CNNs que nous avons adopté dans notre travail donne de bons résultats en classification d'images IRM de tumeurs cérébrales.

10. Graphic interface :

Pour mieux représenter notre résultat on a créé une interface graphique par l'utilisation de la Toolbox **matlab Guide**.



Figure III.4 : Interface graphique représente les résultats final

11. Segmentation sémantique des tumeurs cérébrales en utilisant les bibliothèques Deep Learning de python :

Cet exemple montre comment effectuer une segmentation sémantique de tumeurs cérébrales à partir d'images médicales 3D.

La segmentation sémantique d'images médicales consiste à assigner chaque pixel de l'image à une étiquette bien précise, par exemple l'appartenance à un organe donné, et donc détecter certaines malformations, des anomalies ou des tumeurs et par conséquent, aider les médecins à suggérer un diagnostic approprié.

Il existe plusieurs architectures de réseaux de neurones standard qui ont apporté des contributions significatives au domaine de la vision par ordinateur étant souvent utilisés comme base des systèmes de segmentation sémantique. On peut citer en guise d'exemple : AlexNet, ResNet, VGG-16 et GoogLeNet et bien évidemment le U-Net.

Cette partie illustre l'utilisation d'un *3-D U-Net deep learning network* pour effectuer une segmentation sémantique binaire des tumeurs cérébrales dans l'imagerie par résonance magnétique (IRM). U-Net est un réseau rapide, efficace et simple qui est devenu populaire dans le domaine de la segmentation sémantique.

11.1.1 Python

Le langage Python est un langage de programmation open source multi-plateformes et orienté objet. Grâce à des bibliothèques spécialisées, Python s'utilise pour de nombreuses situations comme le développement logiciel, l'analyse de données, ou la gestion d'infrastructures.

Langage principalement utilisé pour le machine learning et la data science, Python a fortement contribué à l'essor du big data. Grâce à ses nombreuses bibliothèques telles Panda, Bokeh, Numpy, Scipy, Scrapy, Matplotlib, Scikit-Learn ou encore TensorFlow, Python offre une grande flexibilité dans les tâches à effectuer et une grande compatibilité quelle que soit la plateforme utilisée.

11.2. TensorFlow

TensorFlow est une plate-forme open source pour l'apprentissage automatique et une bibliothèque mathématique symbolique utilisée pour les applications d'apprentissage automatique.

11.3. Keras

Il s'agit d'une bibliothèque de réseaux de neurones Open Source qui s'exécute sur Theano ou Tensorflow. Il est conçu pour être rapide et facile à utiliser pour l'utilisateur. C'est une bibliothèque utile pour construire n'importe quel algorithme d'apprentissage en profondeur (Deep learning).

11.4. Dataset

Le Dataset BraTS 2020[29] contient des IRM de tumeurs cérébrales, à savoir les gliomes, qui sont les tumeurs malignes cérébrales primaires les plus courantes. BraTS s'est toujours concentré sur l'évaluation des dernières méthodes de segmentation des tumeurs cérébrales dans les imageries par résonance magnétique (IRM) multimodales. BraTS 2020 utilise des examens IRM préopératoires multi-institutionnels et se concentre principalement sur la segmentation des tumeurs cérébrales intrinsèquement hétérogènes.

Le Dataset contient 750 volumes 4-D, représentant chacun une ensemble d'images 3D. Chaque volume 4-D est de taille 240-par-240-par-155-par-4, où les trois premières dimensions correspondent à la hauteur, la largeur et la profondeur d'une image volumétrique 3D. La quatrième dimension correspond aux différentes modalités de scan.

Le Dataset est divisé en 484 volumes d'entraînement avec des étiquettes de voxel, et 266 volumes de test. La taille de Dataset est d'environ 7 Go.

11.5 L'architecture U-Net

L'idée principale derrière les CNNs est d'apprendre le mappage de fonctionnalités d'une image. Cela fonctionne très bien dans les problèmes de classification lorsque l'image est convertie en un vecteur qui est utilisé après pour la classification. Mais dans la segmentation d'image, on doit non seulement la convertir en vecteur, mais aussi reconstruire une image à partir de ce vecteur. C'est une tâche gigantesque, car il est beaucoup plus difficile de convertir un vecteur en image que l'inverse. Toute l'idée d'U-Net tourne autour de ce problème.

U-Net, issu du réseau de neurones CNN traditionnel, a été conçu et appliqué pour la première fois en 2015 pour traiter les images biomédicales. Il est capable de localiser et de distinguer les frontières des éléments composant une certaine image en faisant la classification sur chaque pixel.

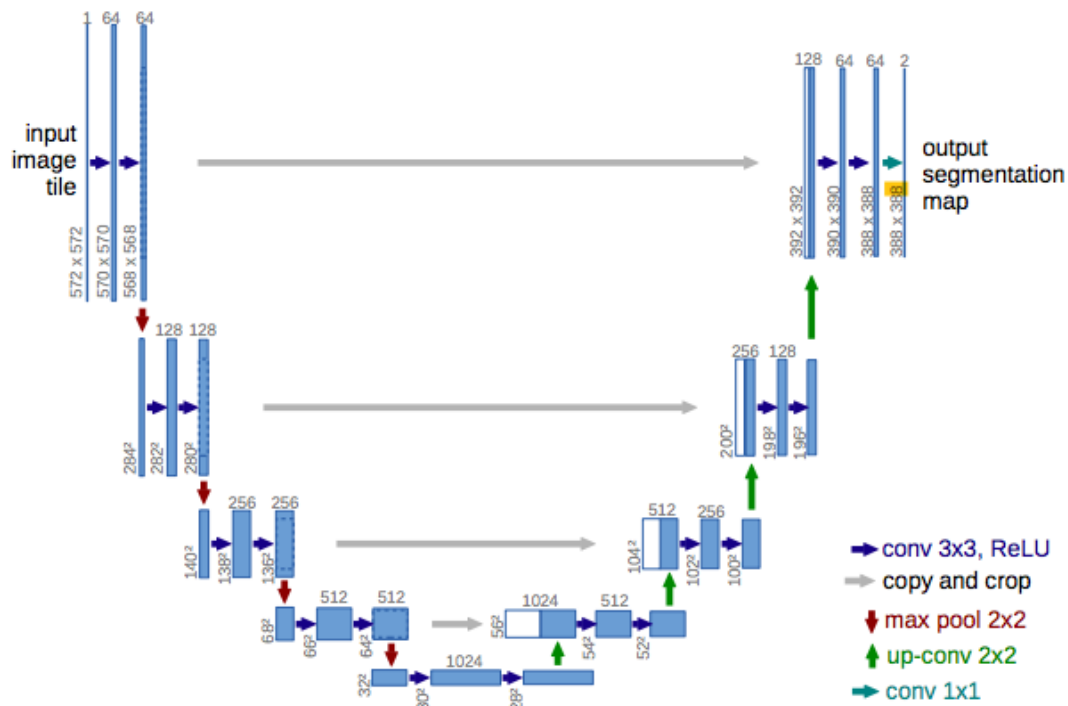


Figure III.5 : Architecture du réseau de neurones U-Net.

Visuellement, il a une forme en « U ». L'architecture est symétrique et se compose de trois sections : La contraction, le goulot d'étranglement et la section d'expansion.

- **Le premier bloc** aussi appelé **encodeur** est utilisé pour récupérer le contexte d'une image. Ce bloc consiste en un assemblage de couches de convolution et de couches de max pooling permettant de capturer les caractéristiques d'une image et de réduire sa taille pour diminuer le nombre de paramètres du réseau. Cela consiste en l'application répétée de deux couches de convolution 3x3. Chaque couche est suivie d'une fonction d'activation ReLU et d'une normalisation par lots (*batch normalization*). Ensuite, une opération de max pooling 2x2 est appliquée pour réduire les dimensions spatiales.
- **Le pont**, ou bien le goulot d'étranglement relie l'encodeur et le réseau de décodeurs et complète le flux d'informations. Il se compose de deux couches de convolutions 3x3, où chaque couche est suivie d'une fonction d'activation ReLU.
- **Le second bloc** est celui du décodeur. Il permet la localisation précise grâce à la convolution transposée et permet également de retrouver la taille initiale de l'image. Le bloc décodeur commence par un sur-échantillonnage (*upsampling*) de la carte des caractéristiques suivie d'une couche de convolution 2x2 transposée. Après, deux couches de

convolutions 3x3 sont utilisées, où chaque convolution est suivie d'une fonction d'activation ReLU. La sortie du dernier décodeur passe par une couche de convolution 1x1 avec une fonction d'activation sigmoïde.

U-Net utilise une fonction de perte pour chaque pixel de l'image. La fonction Softmax est appliqué à chaque pixel suivi d'une fonction de perte. Ceci convertit le problème de segmentation en un problème de classification où on doit classer chaque pixel dans l'une des classes.

11.6 Notre approche

Pour effectuer la segmentation sémantique de tumeurs cérébrales dans l'imagerie par résonance magnétique (IRM) de la base BraTS 2020 nous allons suivre les étapes suivantes :

Step 1 : Préparez les données.

Step 2 : Définir un générateur de données personnalisé.

Step 3 : Définir le modèle 3D U-net.

Step 4 : Train and Predict.

- Dataset information:

Le Dataset contient des Scans multimodales disponibles sous forme de fichiers NIFTI (.nii.gz). Quatre "canaux" d'information - 4 volumes différents de la même région :

- Native (**T1**).
- Post-contrast T1-weighted (**T1CE**).
- T2-weighted (**T2**).
- T2 Fluid Attenuated Inversion Recovery (**FLAIR**) volumes.

Tous les images de Dataset ont été segmentés manuellement et approuvés par des neuro-radiologues expérimentés.

- **Annotations (labels)**: le masque contient les étiquettes(labels) suivantes :

Label 0: Volume sans label.

Label 1: Noyau tumoral nécrotique et non rehaussé (NCR/NET).

Label 2: Peritumoral edema (ED).

Label 3: Manquante (Aucun pixel dans tous les volumes ne contient label 3).

Label 4: Tumor rehaussé (ET).

La figure III.5 représente les quatre canaux d'information et le mask d'une image de la base BraTS 2020 :

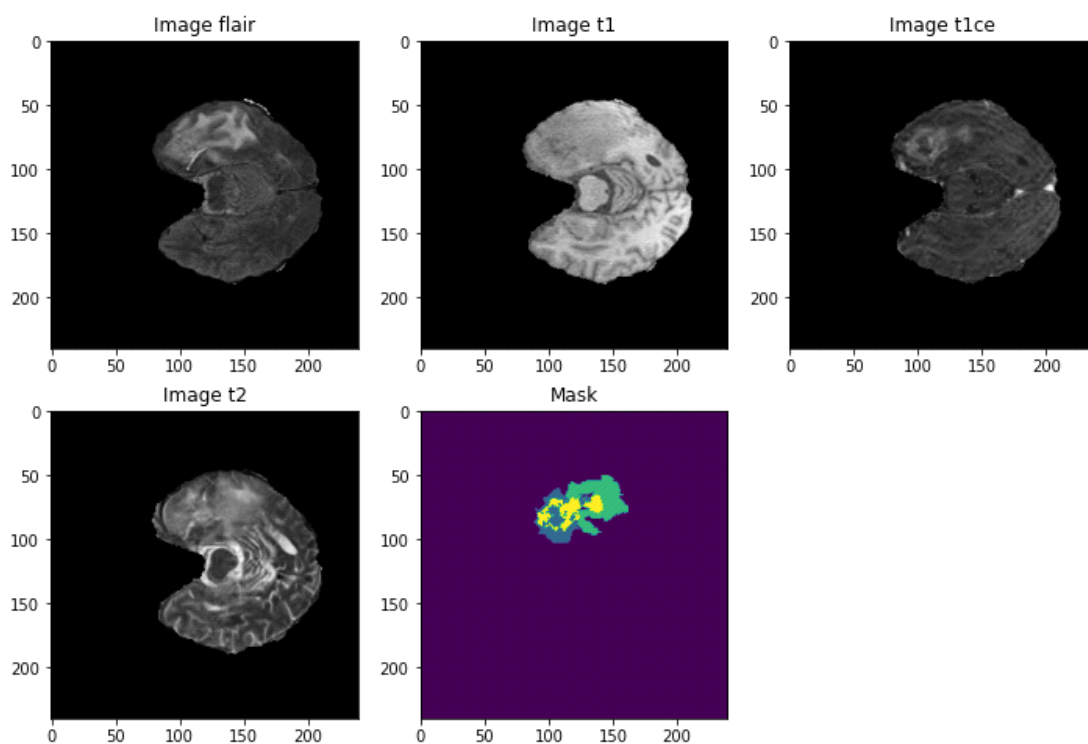



Figure III.6 : Quatre canaux d'information et le mask d'une image de la base BraTS 2020.

La figure III.6 représente les résultats obtenus par notre approche sur quelques images de test de la base BraTS 2020 :



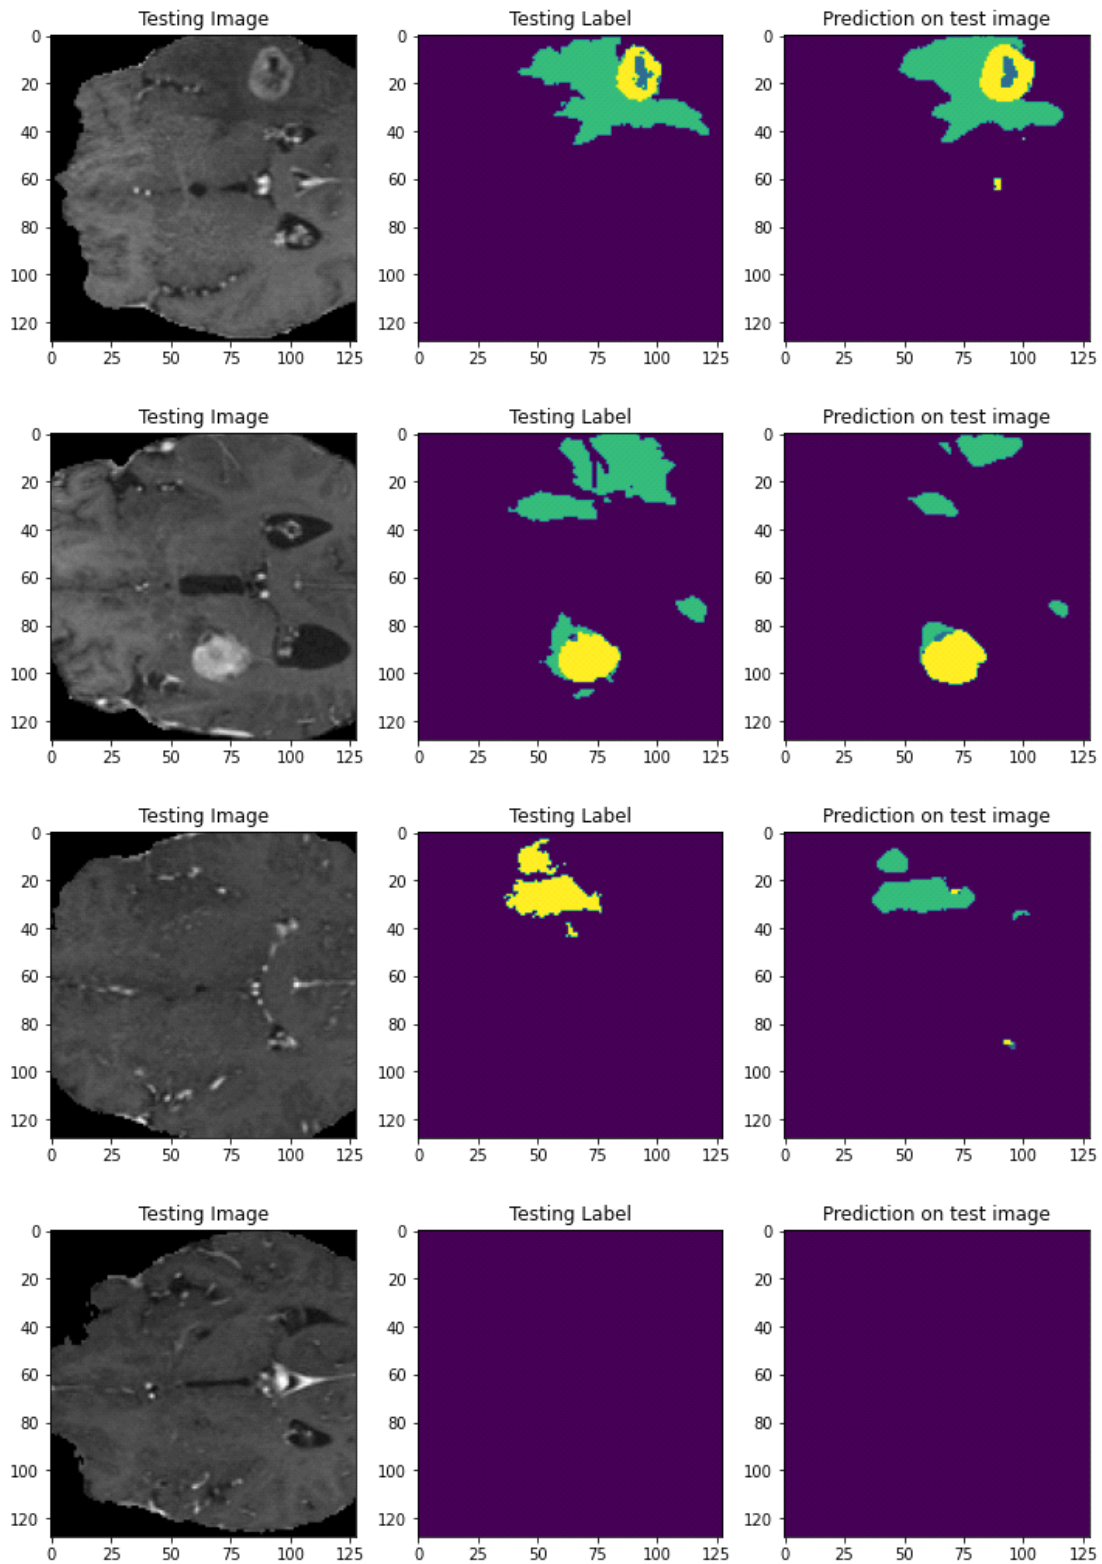


Figure III.7 :Résultats obtenus sur quelques images de test de la base BraTS 2020.

A partir de la figure III.6 on voit que la segmentation sémantique de tumeurs cérébrales dans l'imagerie IRM de la base BraTS 2020 avec l'approche proposée donne des bons résultats.

11.7 Graphic interface

Pour mieux représenter notre résultat on a créé une interface graphique par l'utilisation de la bibliothèque **pyqt5**.



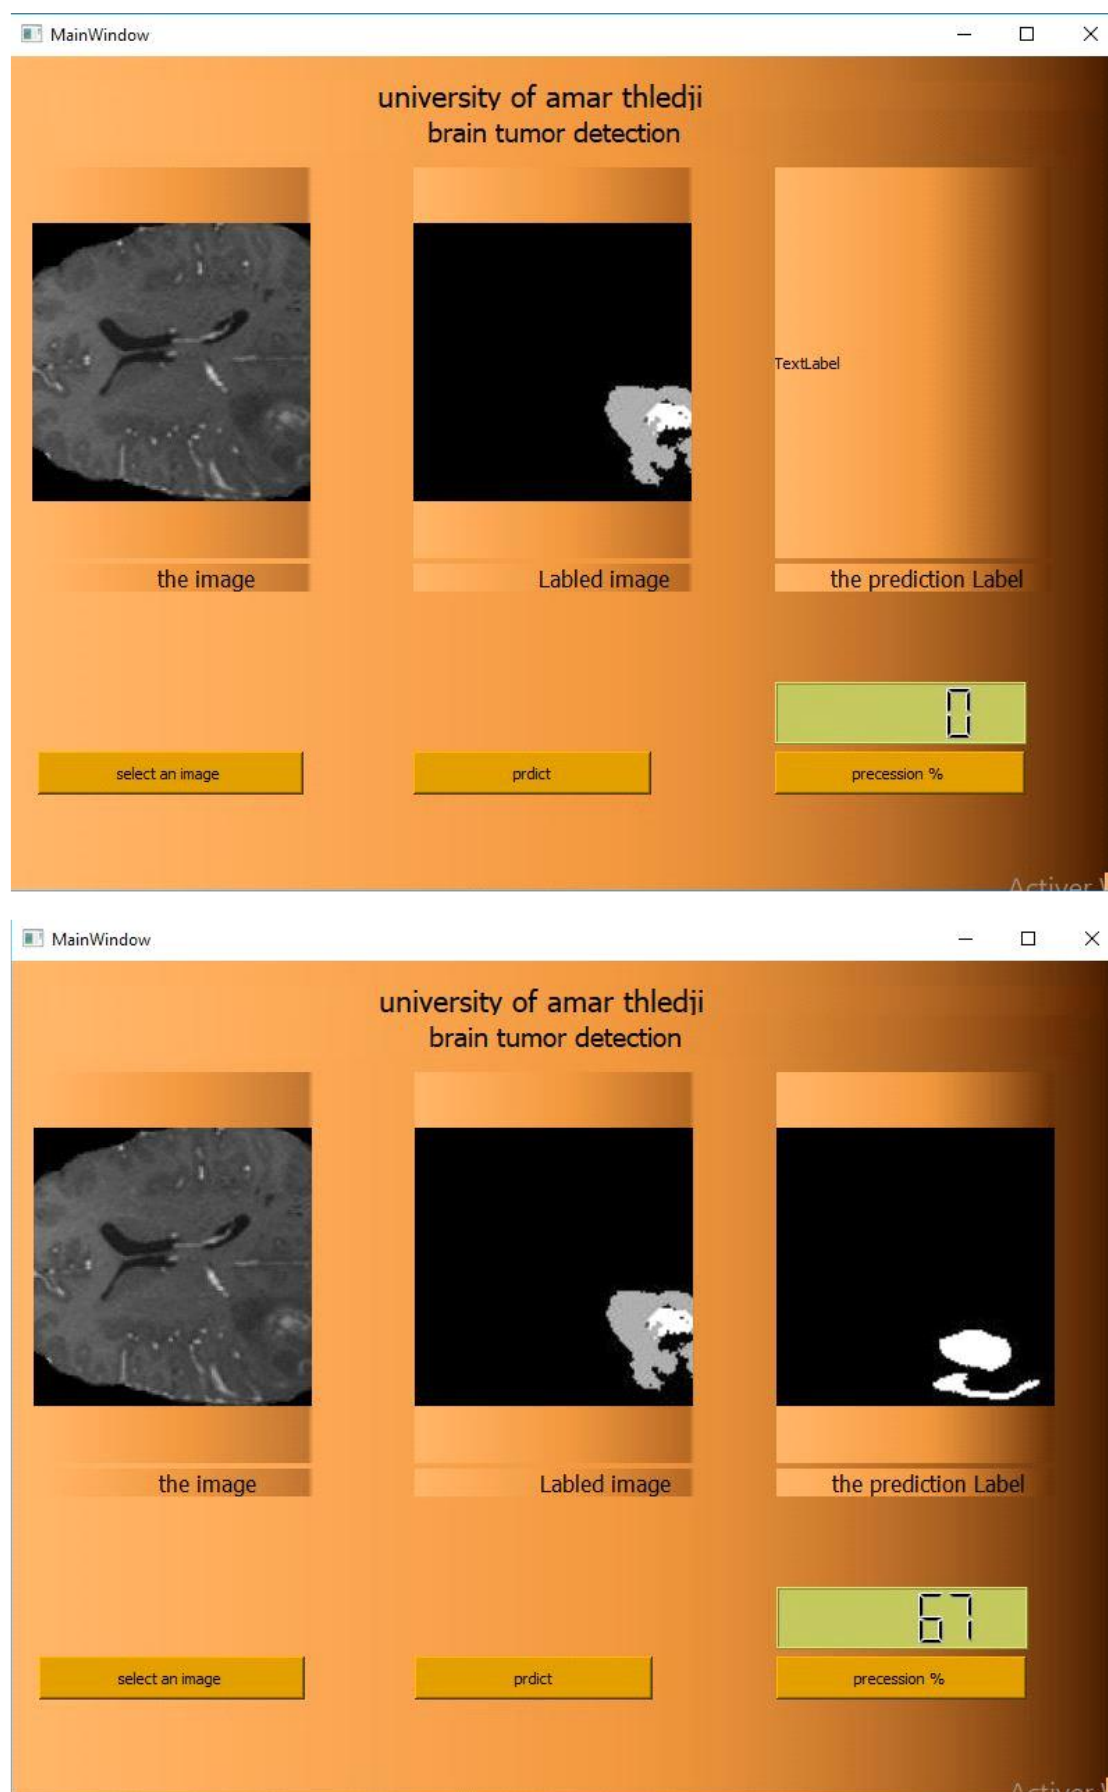


Figure III.8 : Interface graphique représente les résultats obtenus.

Remarque : Ces résultats ne peuvent être pris en compte qu'avec l'approbation de spécialistes dans ce domaine

12. Conclusion

Dans ce chapitre nous avons expliqué les différentes étapes à suivre pour faire la classification de tumeurs cérébrales dans l'imagerie par résonance magnétique (IRM). Afin de réaliser notre implémentation et de pouvoir classer l'ensemble des images de cerveau, nous avons utilisé deux outils logiciel qui sont Matlab et python.

Nous avons vu que la segmentation de tumeurs cérébrales avec l'approche proposée donne des bons résultats .On peut conclure que les modèles CNNs que nous avons adopté dans notre travail donne de bons résultats en classification d'images IRM de tumeurs cérébrales.

Conclusion Générale

Conclusion Générale

Dans ce travail nous avons utilisé le Deep Learning, la méthode d'apprentissage qui a montré de grandes performances ces dernières années dans ce domaine et nous avons adopté la méthode CNNs comme méthode de classification. Nous avons discuté des notions fondamentales des réseaux de neurones en général et des réseaux de neurones convolutionnels en particulier. Nous avons introduit les CNNs en présentant les différents types de couches utilisées dans la classification d'images. Le choix de cette méthode est justifié par la simplicité et l'efficacité de cette dernière.

Au cours de notre travail et afin de pouvoir réaliser la classification automatique de l'ensemble d'images, nous avons adopté deux modèles CNNs à savoir AlexNet et GoogleNet. Les deux modèles CNNs que nous avons adopté dans notre travail donne de bons résultats en classification d'images IRM de tumeurs cérébrales.

Comme deuxième partie nous avons utilisé un 3-D U-Net deep learning network pour effectuer une segmentation sémantique binaire des tumeurs cérébrales dans l'imagerie par résonance magnétique (IRM).L'approche proposée pour faire la segmentation sémantique dans l'imageries IRM de la base BraTS 2020 donne des bons résultats.

Reference

Références Bibliographie

[1] LOUNIS Katia, MOUSSI Dahbia. “ La Classification d’images d’insectes ravageurs en utilisant le Deep Learning “, Mémoire de master en informatique, 2020, UNIVERSITE MOULOUD MAMMARI DE TIZI-OUZOU, Algérie.

[2]Tahia Tazin, Sraboni Sarker et al. “A Robust and Novel Approach for Brain Tumor Classification Using Convolutional Neural Network “, Hindawi, Computational Intelligence and Neuroscience, 2021.

Chaptrer1

[3] : Mme KLOUCHE BADIA “Analyse et classification des images médicales”, Mémoire Magister en informatique, Université d’Oran Mohamed Boudiaf,2016

[4] : http://www.enmarche.be/sante/actes_techniques/Radiographie.htm

[5] :[HTTP://WWW.ENMARCHE.BE/SANTE/THERAPIES_ET_TECHNIQUES/ECHOGRAPHIE.H](http://WWW.ENMARCHE.BE/SANTE/THERAPIES_ET_TECHNIQUES/ECHOGRAPHIE.H)
TM

[6] : <http://www.doctissimo.fr/html/sante/imagerie/scanner.htm>

[7] : [HTTP://WWW.INFO-RADIOLOGIE.CH/MAMMOGRAPHIE.PHP](http://WWW.INFO-RADIOLOGIE.CH/MAMMOGRAPHIE.PHP)

[8] <http://www.genou.com/irm/irm.htm>

[9] :M.Sandeli, " traitement d’images par des approches bio-inspirées application à la segmentation d’images ", Mémoire Magister en informatique, université Constantine 2. 2014.

[10] :S. DOUMANDJI- Y. BOULFANI, " Système de vision par ordinateur ", Séminaire, ENP 2002-2003.

Chaptrer2

[11] : Mémoire master sous l’intitulé : L’intelligence artificielle principe, outils et Objectifs réalisé par Zara Islem de UNIVERSITE BADJI MOKHTAR ANNABA 2019.

[12] : Mémoire de fin d’études de la 2ème année de Master : L’INTELLIGENCE ARTIFICIELLE AU SERVICE DE LA RECHERCHE CLINIQUE (2018 – 2019) université de Lille.

[13] : <http://www.onisep.fr/Pres-de-chez-vous/Hauts-de-France/Amiens/Informations-metiers/Le-numerique-et-l-intelligence-artificielle/L-intelligence-artificielle-et-ses-domaines-d-application>

Références Bibliographie

[14] : "Backpropagation appliquée à la reconnaissance de code postal manuscrite", Neural Computation , 1989. Y. LeCun, B. Boser, JS Denker, D. Henderson, RE Howard, W. Hubbard, et al. (Auteurs)

[15] : <https://www.lebigdata.fr/deep-learning-definition>

[16]:<https://missinglink.ai/guides/convolutional-neural-networks/convolutional-neural-network-architecture-forging-pathways-future/>

[17]:<https://www.anakeyn.com/2020/01/13/classification-de-pages-web-via-deep-learning-reseau-de-neurones-convolutif/>

[18]:<https://www.natural-solutions.eu/blog/la-reconnaissance-dimage-avec-les-reseaux-de-neurones-convolutifs#:~:text=Qu'est%20ce%20que%20la,%C3%A0%20la%20reconnaissance%20d'images>

[19] :<https://datakeen.co/3-deep-learning-architectures-explained-in-human-language/>

[20]:<https://datasciencetoday.net/index.php/fr/deep-learning/173-les-reseaux-de-neurones-convolutifs>

[21]:<https://datasciencetoday.net/index.php/fr/deep-learning/173-les-reseaux-de-neurones-convolutifs>

[22]:<https://medium.com/@yannicksergeobam/comprendre-les-reseaux-de-neurones-convolutifs-cnn-d5f14d963714>

[23]:<https://medium.com/@yannicksergeobam/comprendre-les-reseaux-de-neurones-convolutifs-cnn-d5f14d963714>

[24] : Classification de données massives de télédétection . (Classification of big remote sensing data). Nicolas Audebert: Bretagne Loire University, Rennes, France (2018)

[25] : Reconnaissance d'iris par les réseaux de neurones convolutionnels ». Mémoire Présenté en vue de l'obtention du diplôme de MASTER. 2019.

[26]:<https://livebook.manning.com/book/grokking-deep-learning-for-computer-vision/chapter-5/v-3/34>

[27] :« Going Deeper with Convolutions » Christian Szegedy, Wei Liu, YangqingJia, Pierre Sermanet, Scott Reed, Dragomir Anguelov, Dumitru Erhan, Vincent Vanhoucke, Andrew Rabinovich 17 Sep 2014

Chaptrer3

[28] : <https://www.kaggle.com/datasets/navoneel/brain-mri-images-for-brain-tumor-detection>

[29] : <https://www.kaggle.com/datasets/awsaf49/brats20-dataset-training-validation>

Références Bibliographie
