



**REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE**  
**Ministère de l'Enseignement Supérieur et de la Recherche Scientifique**  
**Université Mohamed Khider – BISKRA**

**Faculté des Sciences Exactes, des Sciences de la Nature et de la Vie**

**Département d'informatique**

N° d'ordre : ....M2/2021

## **Mémoire**

Présenté pour obtenir le diplôme de master académique en

# **Informatique**

Parcours : Intelligence Artificielle (IA)

---

# **Détection de tumeur cérébrale avec l'apprentissage profond**

---

**Par :**

**OTMANI CHAHINEZ**

Soutenu le 27/06/2022 devant le jury composé de :

BEN SEGHIR Nadia

MCA

Président

ABABSA Tarek

MCB

Rapporteur

HATTAB Dalila

MAA

Examineur

Année universitaire 2021-2022

# الجمهورية الجزائرية الديمقراطية الشعبية

وزارة التعليم العالي والبحث العلمي

جامعة محمد خيضر بسكرة

## تصريح شرفي

(خاص بالالتزام بقواعد النزاهة العلمية لإنجاز بحث)

أنا الممضي أسفله،

السيد (ة): عثمانى شهيناز الصفة: طالبة.

الحامل لبطاقة التعريف الوطنية رقم: 200896085 والصادرة بتاريخ: 2016-12-27

المسجل بكلية: العلوم الدقيقة وعلوم الطبيعة والحياة

قسم: الإعلام الآلي - تخصص ذكاء اصطناعي

والمكلف بإنجاز مذكرة تخرج في الماستر عنونها:

Détection de tumeur cérébrale avec l'apprentissage profond

أصرح بشرفي أنني ألتزم بمراعاة المعايير العلمية والمنهجية ومعايير الأخلاقيات المهنية والنزاهة الأكاديمية المطلوبة في إنجاز البحث المذكور أعلاه.

التاريخ: 2022-06-22

توقيع المعني:

## *Remerciements*

Tout d'abord, je remercie **Dieu** le tout-puissant de m'avoir donné le courage et la volonté de faire ce travail.

Je tiens à remercier mon encadreur, **Dr ABABSA Tarek** pour ses multiples conseils, sa patience et son soutien.

Je remercie également les membres de jury **Dr BEN SEGHIR Nadia, Dr HATTAB Dalila** pour l'honneur qu'elles m'ont fait en acceptant de juger notre humble travail.

Je remercie **ma chère mère** qui m'a soutenu et m'a appuyé moralement.

## *Dédicace*

Je dédie cet humble travail à la mémoire de l'âme de **mon cher père**, qui m'a bien soutenu dans ma première réussite, et qui n'a pas eu l'honneur d'assister à cette dernière, à **ma mère** qui a été très patiente avec moi, à tous **mes frères et sœurs**, et à **mon marie**, et ma fille **Meriem**

## ملخص

يعد اكتشاف أورام المخ في أقرب وقت ممكن أمراً ضرورياً لبقاء المريض على قيد الحياة. سبب لتطوير تقنية كشف جديدة. يعتبر ورم المخ من الأمراض الخطيرة في المجال الطبي، يعمل الأطباء بجد للكشف عن الورم وعلاجه لإنقاذ حياة المرضى، يستغرق اكتشاف الورم وقتاً طويلاً بالنسبة للأطباء ويمكن أن يتغير التشخيص من طبيب إلى آخر. التعلم العميق قادر على اكتشاف الورم في المخ باستخدام شبكة عصبية تلافيفية عن طريق صور التصوير بالرنين المغناطيسي IRM، هو أسلوب التصوير الطبي المرجعي للحصول على صور مفصلة للغاية للدماغ لأنه يجعل من الممكن إبراز العديد من خصائص الأنسجة الدماغية.

يصف هذا العمل اكتشاف أورام المخ باستخدام خوارزمية الشبكة العصبية التلافيفية CNN . هدفنا هو الكشف عن أورام المخ وإنشاء هذا النظام لإنقاذ حياة المرضى. لذا فإن نظامنا يقوم على ثلاث خطوات ضرورية. المعالجة المسبقة للصور، استخراج الميزات بنموذج CNN ، وأخيراً طبقات متصلة بالكامل من CNN لتصنيف صور التصوير بالرنين المغناطيسي على أنها طبيعية أو ورم.

**الكلمات المفتاحية:** ورم الدماغ، CNN ، التعلم العميق ، التصوير بالرنين المغناطيسي ، الكشف.

## Résumé

Détecter les tumeurs au cerveau le plus tôt possible est essentiel pour la survie des patients. Raison pour laquelle des nouvelles techniques de détection automatique sont développées au fil du temps. La tumeur du cerveau est une maladie critique. Les médecins travaillent dur pour détecter et traiter la tumeur afin de sauver la vie des patients. La détection de la tumeur prend beaucoup de temps pour les médecins et les diagnostics peuvent changer d'un médecin à un autre. Le deep learning est une technique permettant de détecter la tumeur cérébrale utilisant les réseaux de neurones à convolution à l'aide des images IRM.

Ce travail décrit la détection des tumeurs cérébrales à l'aide des réseaux de neurones convolutifs « CNN ». La détection des tumeurs cérébrales est notre objectif pour créer ce système afin de sauver la vie des patients. Donc, notre système se base sur trois étapes nécessaires à savoir : Prétraitement d'images, extraction de caractéristiques avec le modèle CNN. Et enfin, Les couches entièrement connectées de CNN pour classifier l'IRM en normale ou tumorale.

**Mots clés :** Tumeur cérébrale, CNN, Deep Learning, IRM, Détection.

## **Abstract**

Finding brain tumors as early as possible is essential for patient survival. Reason why a new detection technique developed. Brain tumor is a critical disease in the medical field. Doctors work hard to detect and treat the tumor to save the lives of patients. Tumor detection takes a long time for doctors and diagnoses can change from doctor to doctor. Deep learning capable of detecting a brain tumor with a convolutional neural network using MRI images, or magnetic resonance imaging, is the reference medical imaging technique for obtaining very detailed images of the brain because it makes it possible to highlight many characteristics of cerebral tissues.

This work describes the detection of brain tumors using the CNN convolutional neural network algorithm. Brain tumor detection is our goal to create this system to save the lives of patients. So our system is based on three necessary steps. Image preprocessing, feature extraction with the CNN model. And finally, Fully connected layers of CNN to classify MRI as normal or tumor.

**Keywords :** Brain Tumor, CNN, Deep Learning, MRI, Detection.

## *Liste Des Abréviations et Acronymes*

**IA** : Intelligence Artificielle

**ANN /RNA** : Réseau de neurones artificiels

**DSP** : Digital Signal Processor : processeur de signal numérique

**ML** : Machine Learning

**DL** : Deep Learning

**CNN** : Réseau de Neurones Convolutifs

**IRM** : Imagerie par résonance magnétique

**ADN** : Acide DésoxyriboNucléique

**SNC** : le système nerveux central

**LCR** : le liquide céphalo-rachidien

**LCS** : le liquide cérébro-spinal

**FID** : Free Induction Decay

**MLP** : Multi-Layer Perceptron, MLP : le perceptron multicouche

**RNN** : les réseaux de neurones récurrents

**DAE / SAE** : les réseaux d'auto-encodeurs profonds / empilés

**CD** : la divergence contrastive

**CONV** : la couche de convolution

**POOL** : la couche de pooling

**BN** : BatchNormalisation

**FC** : Fully connected (les couches entièrement connectées)

**CPU** : Central Processing Unit : unité centrale de traitement

**GPU** : graphical processing unit : unité de traitement graphique



# *Table des matières*

<i>Introduction générale</i> .....	1
------------------------------------	---

## *Chapitre 1 : Tumeur Cérébrale et L'imagerie*

### *Par Résonance Magnétique (IRM)*

<b>1.1 Introduction</b> .....	4
<b>1.2 Qu'est-ce qu'un cancer ?</b> .....	4
1.2.1 La division cellulaire.....	4
1.2.2 Une orchestration précise qui se dérègle.....	5
1.2.3 Les caractéristiques d'une cellule cancéreuse.....	6
1.2.4 L'évolution d'un cancer au sein de l'organisme.....	7
<b>1.3 Qu'est-ce qu'un cancer du cerveau ?</b> .....	7
1.3.1 Un peu d'anatomie pour comprendre le cerveau.....	8
1.3.1.1 Que se passe-t-il à l'intérieur du cerveau.....	8
1.3.1.2 Les différentes parties du cerveau et leurs fonctions.....	9
1.3.2 Le cerveau, un organe sous haute protection.....	12
<b>1.4 Les Tumeurs du cerveau</b> .....	13
<b>1.5 Les Causes des tumeurs du cerveau</b> .....	14
<b>1.6 Les symptômes et le diagnostic des tumeurs du cerveau</b> .....	16
1.6.1 Les symptômes possibles.....	16
1.6.1.1 Tumeur du cerveau.....	16
1.6.1.2 Tumeur à la moelle épinière.....	16
1.6.2 Le Diagnostic.....	17
1.6.2.1 L'examen clinique et neurologique .....	17
1.6.2.2 Les examens d'imagerie.....	18
<b>1.7 Imagerie par résonance magnétique (IRM)</b> .....	20
1.7.1 Une IRM, comment ça marche ?.....	20

1.7.2	Que faut-il signaler au médecin et lors de la prise de rendez-vous ?.....	21
1.7.3	Comment se préparer le jour de l'IRM ? .....	21
1.7.4	Comment se déroule une IRM ? .....	22
1.7.5	Le principe physique de l'IRM .....	23
1.7.6	La formation des images IRM .....	25
1.7.7	Les différentes pondérations .....	27
1.7.8	Défauts des images IRM (artefacts).....	29
1.7.9	Avantage des images IRM .....	31
1.8	<b>Conclusion</b> .....	31

## ***Chapitre 2 : Apprentissage Profond (Deep Learning)***

2.1	<b>Introduction</b> .....	34
2.2	<b>Généralités sur les réseaux de neurones artificiels</b> .....	35
2.3	<b>Historique du deep learning</b> .....	40
2.4	<b>Définition de l'apprentissage profond (Deep Learning)</b> .....	40
2.5	<b>Pour quoi l'apprentissage profond (DL) ?</b> .....	41
2.6	<b>L'importance de l'apprentissage profond (DL)</b> .....	41
2.7.	<b>Comment fonctionne l'apprentissage profond ?</b> .....	43
2.8	<b>Principe de l'apprentissage profond (DL)</b> .....	44
2.9	<b>Classification de l'apprentissage profond</b> .....	45
2.10	<b>Les différents types de modèles</b> .....	46
2.10.1	Réseau de neurones récurrents (RNN).....	46
2.10.2	Perceptrons multicouches.....	47
2.10.3	Modèle génératif (deep generative model) .....	48
2.10.4	Réseaux de neurones convolutifs (CNN).....	49
2.10.4.1	Introduction.....	49
2.10.4.2	Définition de réseau de neurones convolutif .....	49
2.10.4.3	CNN vs ANN.....	50

<b>2.10.4.4</b>	Les différentes couches des réseaux de neurones convolutifs.....	51
<b>2.10.4.4.1</b>	La Couche de convolution CONV.....	52
<b>2.10.4.4.2</b>	Couche de correction (ReLU).....	55
<b>2.10.4.4.3</b>	La couche pooling (POOL).....	56
<b>a.</b>	Max Pooling.....	56
<b>b.</b>	Moyenne Pooling.....	56
<b>c.</b>	Global pooling.....	57
<b>2.10.4.4.4</b>	Couche entièrement connectée (FC).....	57
<b>2.10.4.4.5</b>	Couche de dé-convolution.....	57
<b>2.10.4.4.6</b>	Couche de perte (LOSS).....	57
<b>2.10.4.4.7</b>	Couche de normalisation (BN).....	57
<b>2.10.4.4.8</b>	Couche de régularisation (Dropout).....	57
<b>2.10.4.5</b>	Quelques réseaux convolutifs célèbres.....	58
<b>2.10.4.6</b>	Transfert Learning.....	59
<b>2.11</b>	Conclusion.....	60

## ***Chapitre 3 : Conception du système***

<b>3.1</b>	Introduction.....	62
<b>3.2</b>	Principes de réseau de neurones à convolution.....	62
<b>3.3</b>	Construction du modèle CNN.....	62
<b>3.4</b>	Structure des données.....	63
<b>3.5</b>	Augmentation des données.....	63
<b>3.6</b>	Architecture de notre système.....	64
<b>3.7</b>	Mise en œuvre de notre système.....	64
<b>3.8</b>	La base de données.....	66
<b>3.9</b>	Prétraitement des images IRM.....	67
<b>3.9.1</b>	Redimensionnement d'image.....	67
<b>3.9.2</b>	Recadrage d'image.....	67
<b>3.9.3</b>	Augmentation de données.....	67

<b>3.10</b>	<b>Architecture du modèle CNN de notre système.....</b>	<b>68</b>
<b>3.11</b>	<b>Procédure de détection d'une tumeur cérébrale en utilisant CNN.....</b>	<b>69</b>
<b>3.12</b>	<b>Conclusion.....</b>	<b>69</b>

## ***Chapitre 4 : Implémentation et résultats***

<b>4.1</b>	<b>Introduction.....</b>	<b>70</b>
<b>4.2</b>	<b>Ensembles de données d'entraînement, de validation et de test .....</b>	<b>70</b>
<b>4.3</b>	<b>Environnement de développement de système.....</b>	<b>72</b>
<b>4.3.1</b>	<b>Environnement matériel.....</b>	<b>72</b>
<b>4.3.2</b>	<b>Environnement logiciel.....</b>	<b>72</b>
<b>4.3.2.1</b>	<b>Le langage de programmation utilisé (Python).....</b>	<b>72</b>
<b>4.3.2.2</b>	<b>Kaggle.....</b>	<b>73</b>
<b>4.3.2.3</b>	<b>Les bibliothèques Python.....</b>	<b>73</b>
<b>4.3.2.4</b>	<b>Google Colab.....</b>	<b>74</b>
<b>4.4</b>	<b>Implémentation et résultat.....</b>	<b>75</b>
<b>4.4.1</b>	<b>Paramètres d'entraînement.....</b>	<b>75</b>
<b>4.4.2</b>	<b>Prétraitement des données.....</b>	<b>76</b>
<b>4.4.3</b>	<b>Architecture de réseau.....</b>	<b>78</b>
<b>4.4.4</b>	<b>Résultat et discussion.....</b>	<b>78</b>
<b>4.4.4.1</b>	<b>Adam optimizer.....</b>	<b>82</b>
<b>4.4.4.2</b>	<b>SGD optimizer.....</b>	<b>82</b>
<b>4.4.5</b>	<b>Ajout d'une couche Dropout a notre réseau.....</b>	<b>83</b>
<b>4.4.6</b>	<b>Recadrage des images IRM et les résultats obtenus.....</b>	<b>84</b>
<b>4.4.7</b>	<b>Augmentation de la base de données, Recadrage des images IRM et les résultats obtenus.....</b>	<b>85</b>
<b>4.5</b>	<b>Le fonctionnement de l'application.....</b>	<b>86</b>
<b>4.5.1</b>	<b>Prétraitement des données, création du modèle CNN, et apprentissage.....</b>	<b>86</b>

4.5.2	La courbe de perte (loss) et la courbe de précision (accuracy).....	86
4.5.3	Partie de test.....	87
4.5.4	Interface de l'application.....	88
4.6	Travaux existants.....	89
4.7	Conclusion.....	90
	<i>Conclusion Générale</i> .....	92
	<i>Bibliographie</i> .....	94

# *Liste des figures*

## *Chapitre 1 : La Tumeur Cérébrale et L'imagerie Par Résonance Magnétique (IRM)*

<b>Figure 1.1</b> - Les Systèmes de réparation des anomalies (une agression extérieure ou une prédisposition génétique).....	5
<b>Figure 1.2</b> - Système de contrôle opérationnel / Système de contrôle non opérationnel.....	6
<b>Figure 1.3</b> - L'évolution d'un cancer au sein de l'organisme.....	7
<b>Figure 1.4</b> - Anatomie du système nerveux central (SNC).....	8
<b>Figure 1.5</b> - Les deux hémisphères cérébraux.....	9
<b>Figure 1.6</b> - Les 4 lobes de l'hémisphère gauche.....	10
<b>Figure 1.7</b> - Le Cerveau (coupe sagittale).....	11
<b>Figure 1.8</b> - La protection du cerveau .....	12
<b>Figure 1.9</b> - Scanner du cerveau .....	18
<b>Figure 1.10</b> - IRM du cerveau .....	19
<b>Figure 1.11</b> - Principe général d'un système informatisé d'imagerie .....	21
<b>Figure 1.12</b> - Le mouvement de spin .....	24
<b>Figure 1.13</b> - Mouvement de précession d'un ensemble de moments magnétiques .....	24
<b>Figure 1.14</b> - Décomposition du moment magnétique M en un moment transversal $M_T$ et longitudinal $M_L$ lors de la résonance .....	25
<b>Figure 1.15</b> - Signal FID recueilli par les bobines réceptrices .....	26
<b>Figure 1.16</b> - Plans axial, coronal et sagittal (de gauche à droite) sur une acquisition en $T_1$ .....	27
<b>Figure 1.17</b> - Une même coupe obtenue sous différents paramètres d'acquisition .....	27
<b>Figure 1.18</b> - Intérêt d'une acquisition avec injection de gadolinium .....	29
<b>Figure 1.19</b> - L'inhomogénéité RF .....	31

## ***Chapitre 2 : Apprentissage Profond (Deep Learning)***

<b>Figure 2.1</b> - Illustration de l'analogie entre un neurone biologique (à gauche) et un neurone formel (à droite).....	36
<b>Figure 2.2</b> - Schéma d'un réseau de neurones monocouche.....	38
<b>Figure 2.3</b> - Schéma d'un réseau de neurones non bouclé (Perceptron multicouches).....	38
<b>Figure 2.4</b> - Schéma de réseau de neurones bouclé.....	39
<b>Figure 2.5</b> – Définition de Deep Learning.....	41
<b>Figure 2.6</b> - Le procédé du ML classique comparé à celui du Deep Learning.....	43
<b>Figure 2.7</b> - Classification des méthodes d'apprentissage profond.....	46
<b>Figure 2.8</b> - Perceptron multicouches.....	48
<b>Figure 2.9</b> - Structure d'un réseau de neurones convolutifs.....	50
<b>Figure 2.10</b> - Couches d'un réseau de neurone Vs un réseau de neurone à convolutions.....	51
<b>Figure 2.11</b> - Exemple simpliste des valeurs d'une des pixels d'une image 5x5.....	52
<b>Figure 2.12</b> - Exemple de valeurs Matrice utilisée comme filtre.....	52
<b>Figure 2.13</b> – Opération de convolution.....	53
<b>Figure 2.14</b> - Quelques fonctions d'activation.....	55
<b>Figure 2.15</b> - Exemple du Max Pooling.....	56
<b>Figure 2.16</b> - Exemple du Moyenne pooling.....	57
<b>Figure 2.17</b> - Exemple du global pooling.....	57

## ***Chapitre 3 : Conception du système***

<b>Figure 3.1</b> - Architecture de réseau de neurones covolutif.....	63
<b>Figure 3.2</b> - Image en présence d'une tumeur.....	63
<b>Figure 3.3</b> - Image d'un cerveau normal.....	63
<b>Figure 3.4</b> - Une image augmentée.....	64
<b>Figure 3.5</b> - Architecture de notre système.....	65
<b>Figure 3.6</b> - Les différentes étapes de détection d'une tumeur cérébrale par réseau de neurones convolutif.....	66
<b>Figure 3.7</b> – Architecture du modèle CNN de notre système.....	67

## ***Chapitre 4 : Implémentation et résultats***

<b>Figure 4.1</b> – Etiquette et redimensionnement des images IRM.....	77
<b>Figure 4.2</b> – La division de la base de données.....	77
<b>Figure 4.3</b> – Le recadrage des images IRM.....	77
<b>Figure 4.4</b> – Un exemple d’une image IRM avant et après Crop.....	78
<b>Figure 4.5</b> – L’augmentation de la base de données.....	78
<b>Figure 4.6</b> – Un exemple d’une image IRM avant et après l’augmentation.....	78
<b>Figure 4.7</b> – La création du modèle.....	79
<b>Figure 4.8</b> – L’apprentissage (adam optimizer).....	80
<b>Figure 4.9</b> - La perte (loss) et la précision (accuracy) du réseau (adam optimizer).....	80
<b>Figure 4.10</b> - La courbe de perte (loss) et la courbe de précision (accuracy) du réseau (adam optimizer).....	81
<b>Figure 4.11</b> – L’apprentissage (SGD optimizer).....	81
<b>Figure 4.12</b> - La perte (loss) et la précision (accuracy) du réseau (SGD optimizer).....	81
<b>Figure 4.13</b> - La courbe de perte (loss) et la courbe de précision (accuracy) du réseau (SGD optimizer).....	82
<b>Figure 4.14</b> – Résultats obtenus Après Dropout, la précision maximale pour la validation atteint <b>0,9813</b> .....	83
<b>Figure 4.15</b> - La courbe de perte (loss) et la courbe de précision (accuracy) du réseau après Dropout.....	84
<b>Figure 4.16</b> – Résultats obtenus et courbes Après Dropout, et recadrage des IRM, la précision maximale pour la validation atteint <b>0,9798</b> .....	84
<b>Figure 4.17</b> – Résultats obtenus et courbes Après Dropout, recadrage, et augmentation de données des IRM, la précision maximale pour la validation atteint <b>0,9861</b> .....	85
<b>Figure 4.18</b> – Prétraitement des données, création du modèle CNN et apprentissage.....	86
<b>Figure 4.19</b> La courbe de perte (loss) et la courbe de précision (accuracy).....	87
<b>Figure 4.20</b> Deux exemples de test de deux images IRM, avec tumeur et sans tumeur.....	87
<b>Figure 4.21</b> - Interface de l’application.....	89



# *Liste des tableaux*

## *Chapitre 1 : La Tumeur Cérébrale et L'imagerie*

### *Par Résonance Magnétique (IRM)*

**Tableau.1.1** - les principales fonctions des 4 lobes de l'hémisphère gauche.....10

**Tableau 1.2** - Ordre de grandeur des temps de relaxation à 1.5 Tesla.....25

## *Chapitre 2 : Apprentissage Profond (Deep Learning)*

**Tableau 2.1** - Les étapes majeurs du Deep Learning.....40

# *Introduction*

## *Générale*

L'intelligence Artificielle (IA) existe depuis des décennies, initialement inventée en 1956 par John McCarthy Professeur adjoint de l'université de Dartmouth. Toutefois, les progrès étaient limités parce qu'il était extrêmement complexe de programmer à la main les algorithmes. Les activités sophistiquées, comme les diagnostics médicaux, la prédiction de résultats, impliquent des milliers de jeux de données et des relations non linéaires entre les variables. C'est l'accélération de la puissance du calcul informatique qui a permis de rentrer dans l'âge d'or de l'IA. [38]

Cette discipline profite en particulier de la Machine Learning (ML) où les progrès sont rapides et importants, la ML est une branche de l'IA basée sur l'idée que le système apprend un modèle à partir d'une base de données à grande échelle en utilisant des outils probabilistes et statistiques et en prenant des décisions ou des prévisions sur les nouvelles données.

C'est l'imagerie médicale, en particulier en oncologie, qui dispose du plus grand nombre de données nécessaires à l'exploitation de l'IA et de la ML.

La ML pourrait ainsi bénéficier aujourd'hui des nombreuses données obtenues par l'imagerie IRM haute résolution. Il existe plus de 15 méthodes d'apprentissage en ML dont chacune utilise une structure algorithmique différente pour optimiser des prédictions basées sur les données reçues. Une approche particulière, Deep Learning (DL) ou apprentissage approfondi donne actuellement des résultats particulièrement révolutionnaires. [38]

L'enjeu du DL est de modéliser le cerveau pour ne pas traiter les informations avec des règles exhaustives mais plutôt en utilisant la pratique et la rétroaction, à la manière d'un enfant qui découvre le monde, le DL utilise une approche équivalente, inspiré du modèle du cortex visuel. Le DL fonctionne de façon quasi similaire à la fonction des neurones du cerveau humain en formant un réseau neuronal convolutif profond.

L'application du DL s'est particulièrement illustrée dans le domaine de l'imagerie médicale pour la détection des tumeurs. Différentes architectures de réseaux de neurones convolutifs sont de plus en plus étudiées en tant que solutions prometteuses pour concevoir des outils de diagnostic assisté par ordinateur plus précis pour la détection du cancer. C'est la convergence de toutes ces innovations associant réseaux de neurones artificiels multicouches, algorithmes d'analyse discriminante et croissance de la puissance de calcul informatique permettant le traitement de données massives, qui profite à l'applicabilité de l'IA en médecine. [38]

La technologie IRM permet, à l'heure actuelle, de disposer d'images numériques offrant au traicteur d'images la matière nécessaire à la mise en œuvre d'algorithmes de traitement et d'analyse qui visent à aider au diagnostic des tumeurs cérébrales. Ce véritable challenge consiste alors à détecter précisément la zone tumorale. [23]

L'imagerie par résonance magnétique (IRM) a connu un véritable essor ces dernières années. Cette modalité d'imagerie est devenue un outil de plus en plus important en médecine du cerveau ou dans la recherche en neurosciences cognitives, l'IRM permet une visualisation précise de la formation anatomique des tissus du cerveau. [11]

Pour ces raisons, la détection automatique des tumeurs cérébrales devient significative pour éventuellement augmenter la probabilité de survie. Le cancer du cerveau est une maladie critique dans le domaine médical. Les médecins travaillent dur pour détecter et traiter la tumeur afin de sauver la vie des patients. La détection de la tumeur prend beaucoup de temps pour les médecins et les diagnostics peuvent changer d'un médecin à un autre. Nous devons donc essayé de créer un système robuste et fiable pour résoudre ce problème, et ça c'est notre objectif dans ce travail, le système est divisé en plusieurs étapes à savoir: prétraitement, extraction des caractéristiques et classification à l'aide les réseaux de neurones convolutifs.

Ce mémoire s'articule autour de ce schéma :

### **Une introduction générale**

#### **Chapitre 1 : La Tumeur Cérébrale et IRM**

Dans ce chapitre, nous avons présenté en détail tout ce qui concerne les tumeurs cérébrales, et l'image par résonance magnétique.

#### **Chapitre 2 : Apprentissage Profond (Deep Learning)**

Dans ce chapitre, nous présentons les différentes notions liées au réseau de neurones artificiels, les concepts de deep learning, ou sont d'écrites les déférent architecture de cette technique, parmi ces architecture, nous détaillons le réseau de neurones convolutifs (CNN).

#### **Chapitre 3 : Conception du Système**

Dans ce chapitre, nous donnons une description pour le système proposé.

#### **Chapitre 4 : Implémentation et Résultat**

Dans ce chapitre, nous faisons une description de la partie des résultats obtenus.

Ce mémoire se termine par **une conclusion générale.**

# *Chapitre 1*

## *La Tumeur Cérébrale et L'imagerie Par Résonance Magnétique (IRM)*

### **Sommaire**

---

- 1.1 Introduction.**
  - 1.2 Qu'est-ce qu'un cancer ?**
    - 1.2.1 La division cellulaire.
    - 1.2.2 Une orchestration précise qui se dérègle.
    - 1.2.3 Les caractéristiques d'une cellule cancéreuse.
    - 1.2.4 L'évolution d'un cancer au sein de l'organisme.
  - 1.3 Qu'est-ce qu'un cancer du cerveau ?**
    - 1.3.1 Un peu d'anatomie pour comprendre le cerveau.
    - 1.3.2 **Le cerveau, un organe sous haute protection.**
  - 1.4 Les Tumeurs du cerveau.**
  - 1.5 Les Causes des tumeurs du cerveau.**
  - 1.6 Les symptômes et le diagnostic des tumeurs du cerveau.**
    - 1.6.1 Les symptômes possibles.
    - 1.6.2 Le Diagnostic.
  - 1.7 Imagerie par résonance magnétique (IRM)**
    - 1.7.1 Une IRM, comment ça marche ?
    - 1.7.2 Que faut-il signaler au médecin et lors de la prise de rendez-vous ?
    - 1.7.3 Comment se préparer le jour de l'IRM ?
    - 1.7.4 Comment se déroule une IRM ?
    - 1.7.5 Le principe physique de l'IRM.
    - 1.7.6 La formation des images IRM.
    - 1.7.7 Les différentes pondérations.
    - 1.7.8 Défauts des images IRM (artefacts).
    - 1.7.9 Avantage des images IRM.
  - 1.8 Conclusion.**
-

## **1.1 Introduction**

Le cancer du cerveau est parmi les types de cancer les plus critiques, le patient peut avoir plusieurs symptômes dans le corps en fonction de la localisation du cancer dans le cerveau. La détection précoce du cancer peut donner à la personne une nouvelle chance dans sa vie, afin de suivre un traitement efficace pour la sauver.

Les tumeurs sont des blocs de cellules caractérisés par une division incontrôlable, nous pouvons classer les tumeurs cérébrales en deux types selon leur nature, leur origine, leur taux de croissance et leur stade de progression. Le premier type, les tumeurs qui proviennent de cellules dans le cerveau ou de l'enveloppe du cerveau. La tumeur cérébrale métastatique se produit lorsque les cellules cancéreuses se propagent dans le cerveau à partir d'un cancer primitif situé dans une autre partie du corps, il s'agit du deuxième type. [25] Les divers symptômes du cancer du cerveau incluent des problèmes de coordination, des maux de tête fréquents, des sautes d'humeur, des changements d'élocution, des difficultés de concentration des convulsions et une perte de mémoire, qui dépendent de la taille de la tumeur, de sa nature et de son emplacement.

Une fois les symptômes apparus, il est généralement trop tard pour traiter la tumeur. Cependant, il est très difficile de traiter le cancer à des stades plus élevés où les taux de survie sont faibles. [26]

Les scans cérébraux utilisant l'imagerie par résonance magnétique (IRM) sont des méthodes rapides pour la détection des tumeurs. L'imagerie par résonance magnétique (IRM) est devenue une méthode largement utilisée d'imagerie médicale de haute qualité. Cependant les techniques de détection du cancer doivent être fiables et robustes pour que les diagnostics soient corrects. [19]

## **1.2 Qu'est-ce qu'un cancer ?**

Première cause de mortalité, les cancers se développent à partir de cellules anormales qui se multiplient de manière incontrôlée au détriment de l'organisme. La mutation de certains gènes est à l'origine de leur apparition. [20]

### **1.2.1 La division cellulaire**


Chaque individu est constitué de près de 50 000 milliards de cellules organisées en tissus (tissu conjonctif, tissu épithélial, tissu nerveux, tissu musculaire) qui vont eux-mêmes former des organes (cœur, cerveau, poumon, peau...).

Chaque jour, au sein de chaque organe, des milliers de cellules vont se multiplier (par division cellulaire) et d'autres vont mourir. Ce renouvellement constant permet d'assurer le bon

fonctionnement de l'organisme. Il est contrôlé par des milliers de gènes qui agissent ensemble pour « ordonner » aux cellules de se multiplier ou de mourir en fonction de la situation. [20]


### 1.2.2 Une orchestration précise qui se dérègle

Une agression extérieure (alcool, tabac, soleil, virus, radiations...) ou une prédisposition génétique peut être à l'origine d'altérations de l'ADN dont sont composés les gènes. Ces altérations vont parfois conduire à l'apparition de mutations. Heureusement, les cellules possèdent des systèmes de réparation qui permettent de repérer et de corriger ces anomalies.



**Figure 1.1** - Les Systèmes de réparation des anomalies (une agression extérieure ou une prédisposition génétique). [20]

Lorsque les mutations sont trop importantes pour être réparées, la cellule va s'autodétruire, par apoptose. Mais parfois, ces systèmes de sécurité fonctionnent mal ou ne fonctionnent plus : la cellule va alors continuer à se multiplier malgré la présence de mutations non réparées. Si ces dernières touchent des gènes impliqués dans la régulation de la prolifération cellulaire ou de l'apoptose, la cellule peut rapidement se multiplier de manière incontrôlable, conduisant à la formation d'une tumeur. [20]



**Figure 1.2** - Système de contrôle opérationnel / Système de contrôle non opérationnel. [20]

Toutefois, en règle générale, une cellule ne devient pas cancéreuse lorsqu'elle possède une ou deux anomalies génétiques acquises. C'est l'accumulation de nombreuses altérations au cours du temps qui la conduit à acquérir les propriétés d'une cellule cancéreuse. Cela explique en partie pourquoi la fréquence des cancers augmente avec l'âge et avec la durée d'exposition à des agents mutagènes. [20]

### 1.2.3 Les caractéristiques d'une cellule cancéreuse

Les cellules susceptibles de conduire à la formation d'un cancer présentent plusieurs particularités :

- **elles sont immortelles:** en se multipliant activement sans jamais mourir, elles s'accumulent pour former une tumeur.
- **elles n'assurent pas les fonctions des cellules normales dont elles dérivent:** une cellule de cancer du sein ne va pas assurer les fonctions d'une cellule mammaire normale.
- **elles sont capables de détourner les ressources locales pour s'en nourrir:** les tumeurs développent souvent un réseau de vaisseaux sanguins qui leur permet d'être directement alimentées en oxygène, énergie et facteurs de croissance. Ce processus est nommé néo angiogenèse.
- **elles sont capables d'empêcher les défenses immunitaires de l'organisme de les attaquer.** [20]




### **1.2.4 L'évolution d'un cancer au sein de l'organisme**

Au fur et à mesure du temps, les cellules cancéreuses continuent à accumuler des anomalies. Elles acquièrent ainsi de nouvelles propriétés qui vont leur permettre de se développer localement. Elles vont finir par envahir tous les tissus de l'organe dans lequel elles sont nées, puis par atteindre les tissus voisins : à ce stade, le cancer est dit « invasif ».

Par ailleurs, certaines cellules tumorales peuvent devenir mobiles, se détacher de la tumeur et migrer à travers les systèmes sanguin ou lymphatique pour former une tumeur secondaire ailleurs dans l'organisme. On parle de métastase.

Les décès par cancer sont surtout dus aux dommages causés par les métastases. C'est pourquoi il est important de diagnostiquer précocement la maladie, avant sa dissémination dans l'organisme. [20]



**Figure 1.3** - L'évolution d'un cancer au sein de l'organisme. [20]

## **1.3 Qu'est-ce qu'un cancer du cerveau ?**


C'est grâce au système nerveux que le fonctionnement normal d'un être humain est rendu possible : transmission des informations sensorielles, réalisation des mouvements, contrôle du fonctionnement des organes, cognition (mémoire, langage, raisonnement, jugement apprentissage...) et psychisme. On distingue le système nerveux central du système nerveux périphérique :

- **le système nerveux central (SNC)** regroupe le cerveau, le tronc cérébral, le cervelet et la moelle épinière. Lorsque l'on parle de l'encéphale, il s'agit des parties du SNC contenues dans la boîte crânienne (cerveau, tronc cérébral et cervelet).
- **le système nerveux périphérique** correspond aux nerfs qui permettent la transmission des messages entre la moelle épinière et la périphérie (bras, jambes, organes...). [20]

### 1.3.1 Un peu d'anatomie pour comprendre le cerveau

Grâce aux progrès de la science, le fonctionnement du cerveau est de mieux en mieux connu. Nous savons aujourd'hui qu'il fonctionne grâce à des milliards de neurones, connectés entre eux. Nous savons également qu'il est organisé en plusieurs zones, qui gèrent chacune des fonctions différentes.

Cette connaissance du cerveau a permis de mieux comprendre les maladies dont il peut être atteint et de développer des traitements de plus en plus précis et efficaces. [21]



**Figure 1.4** - Anatomie du système nerveux central (SNC). [20]

#### 1.3.1.1 Que se passe-t-il à l'intérieur du cerveau ?

Le cerveau fonctionne comme un ordinateur central. Il reçoit en permanence une multitude d'informations sur ce qui se passe à l'intérieur et à l'extérieur du corps. Ces informations lui proviennent des nerfs rachidiens, qui parcourent l'ensemble du corps et des nerfs crâniens, situés à l'intérieur du crâne. Chaque information est classée, analysée et traitée par des cellules nerveuses, les neurones. Connectés entre eux, les neurones sont capables de gérer plusieurs informations à la fois. C'est ce qui nous permet de voir, de parler, de marcher et de respirer, tout cela en même temps et sans avoir à y réfléchir. [21]

Ces milliards de neurones sont entourés et nourris par d'autres cellules appelées cellules gliales. Les cellules gliales sont dix fois plus nombreuses que les neurones. Elles représentent 90 % de la composition du cerveau. Il en existe différents types : les astrocytes, les


oligodendrocytes, les épendymocytes et les cellules microgliales. Un peu plus de la moitié des tumeurs du cerveau se développent à partir de ces cellules, ce type de tumeur est appelé gliome. [21]

### **1.3.1.2 Les différentes parties du cerveau et leurs fonctions**

Le cerveau est très organisé. Il est composé de plusieurs parties qui ont chacune des rôles spécifiques, tout en étant complémentaires les unes des autres. [21]

- **Les hémisphères cérébraux**

Les hémisphères cérébraux forment les parties les plus volumineuses du cerveau. Ils sont deux : un hémisphère droit et un hémisphère gauche. On parle souvent de cerveau droit et de cerveau gauche. Les hémisphères contrôlent l'ensemble de nos fonctions mentales supérieures : mouvements volontaires, pensée, apprentissages mémoire, etc.



**Figure 1.5** - Les deux hémisphères cérébraux. [21]

Chaque hémisphère est lui-même partagé en quatre zones appelées lobes, dans lesquels ces différentes fonctions sont gérées : le lobe frontal, le lobe pariétal, le lobe temporal et le lobe occipital. [21]

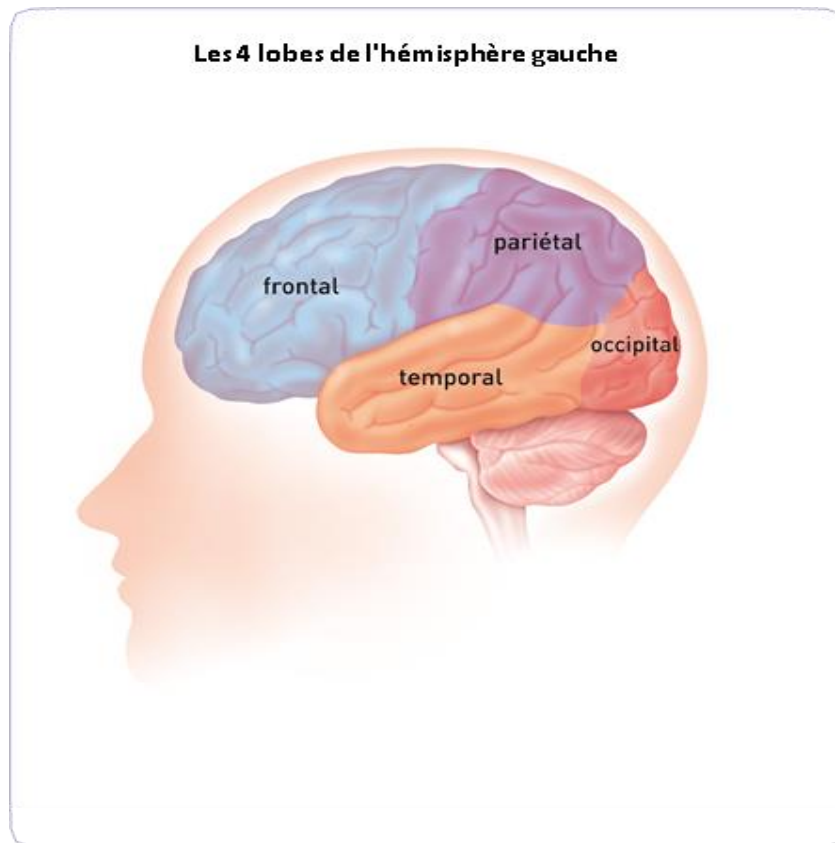


Figure 1.6 - Les 4 lobes de l'hémisphère gauche. [21]

Le tableau ci-dessous présente les principales fonctions de chaque lobe.

Lobes	Principales fonctions
<b>Lobes frontaux</b>	Parole et langage, raisonnement, mémoire, prise de décision, personnalité, jugement, mouvements. Le lobe frontal droit gère les mouvements du côté gauche du corps, et inversement, le lobe frontal gauche gère les mouvements du côté droit
<b>Lobes pariétaux</b>	Lobes pariétaux Lecture, repérage dans l'espace, sensibilité. Là aussi, le lobe pariétal droit gère la sensibilité du côté gauche du corps et réciproquement
<b>Lobes occipitaux</b>	Vision
<b>Lobes temporaux</b>	Langage, mémoire, émotions

Tableau.1.1 - les principales fonctions des 4 lobes de l'hémisphère gauche. [21]

D'une manière générale, l'hémisphère droit commande le côté gauche du corps et inversement. Cependant, la répartition des fonctions à l'intérieur des lobes n'est pas totalement figée. Certaines fonctions sont gérées dans des zones différentes selon les personnes. Ainsi, la zone du langage est généralement située dans le lobe temporal gauche chez les droitiers, alors qu'elle peut être située des deux côtés chez les gauchers. [21]

- **Le tronc cérébral**


Le tronc cérébral relie les hémisphères cérébraux à la moelle épinière. C'est lui qui contrôle les fonctions vitales du corps : battements du cœur, respiration, tension artérielle. Il commande aussi la mobilité des yeux, les mouvements du visage et la déglutition.

- **Le cervelet**

Le cervelet est situé à l'arrière du tronc cérébral, sous les lobes occipitaux. Il nous permet d'avoir des réflexes, de coordonner nos mouvements et de garder l'équilibre.

- **L'hypophyse et l'hypothalamus**

L'hypophyse et l'hypothalamus sont des structures nerveuses situées à la base du cerveau, au milieu du crâne. [21]



**Figure 1.7** – Le Cerveau (coupe sagittale). [21]

De la taille d'un petit pois, l'hypophyse joue un rôle fondamental dans la production des hormones. Elle contrôle de nombreuses fonctions telles que la croissance, la production du lait maternel, la puberté, la fertilité, etc.

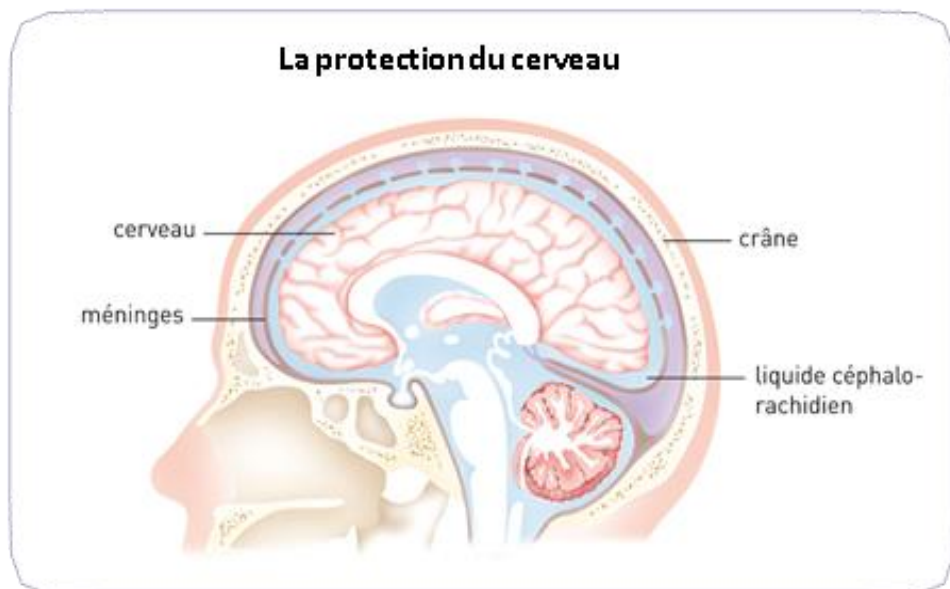
L'hypothalamus, situé un peu au-dessus de l'hypophyse, est en contact avec toutes les autres

zones du cerveau. Il régule les sensations de faim et de soif, la température du corps, le sommeil, la sexualité ou encore les battements du cœur. [21]

### 1.3.2 Le cerveau, un organe sous haute protection

En tant que centre de commande de l'ensemble du corps, le cerveau bénéficie de trois systèmes de protection :

- Les **os du crâne** forment une première coque solide autour du cerveau. Ils le protègent des chocs.
- trois membranes, les **méninges**, enveloppent le cerveau et la moelle épinière. Elles les protègent des blessures et des infections.
- enfin, à l'intérieur du crâne et le long de la colonne vertébrale, un liquide joue le rôle d'isolant et d'amortisseur contre les chocs. Ce liquide est le **liquide céphalo-rachidien** (abrégé en LCR), appelé aussi liquide cérébro-spinal (abrégé en LCS). Il est produit à l'intérieur du cerveau, dans des cavités appelées ventricules. Renouvelé en permanence, ce liquide garde un volume stable, ce qui assure une pression constante à l'intérieur du crâne. [21]



**Figure 1.8** - La protection du cerveau. [21]

## **1.4 Les Tumeurs du cerveau**

Les tumeurs cérébrales sont des masses de cellules qui progressent rapidement, de façon incontrôlée, dans le cerveau. Elles sont de deux types : [20]

- **Les tumeurs primitives** naissent dans le cerveau. On distingue les tumeurs bénignes (deux tiers des cas de tumeurs primitives), composées de cellules non cancéreuses, et les tumeurs malignes, constituées de cellules cancéreuses. [20]

Qu'elles soient bénignes ou malignes, les tumeurs primaires peuvent entraîner des symptômes sérieux en particulier lorsqu'elles sont situées dans des zones fonctionnelles clés du cerveau.

- **Les tumeurs secondaires** sont des métastases d'un cancer préexistant. Elles naissent lorsque des cellules d'une tumeur initiale située hors de l'encéphale parviennent à migrer, via la circulation sanguine, vers le tissu cérébral. [20]

Certains cancers au stade avancé sont fréquemment associés au développement de métastases cérébrales : les cancers du poumon, de la peau, du rein ou du sein.

Il existe plus de 200 tumeurs primitives du cerveau différentes. Chacune porte un nom spécifique selon le type de cellule atteint, sa localisation et son degré d'agressivité. Les tumeurs sont également caractérisées en fonction de la manière dont elles évoluent au sein du tissu cérébral : on parle de tumeur non infiltrante ou circonscrite lorsque ses bords sont bien nets et de tumeur infiltrante lorsqu'il est difficile de distinguer la frontière entre la tumeur et le tissu sain. Cette caractéristique est importante car elle intervient sur le choix des traitements à mettre en œuvre. [20]

Les principales tumeurs cérébrales primitives sont :

- **Les gliomes** il s'agit des tumeurs primitives du cerveau les plus fréquentes (environ un tiers des cas). Les gliomes regroupent un ensemble de tumeurs plus ou moins infiltrantes nées au sein du cerveau à partir des cellules gliales (astrocytes ou oligodendrocytes). Les gliomes constitués d'astrocytes sont appelés astrocytomes et ceux constitués d'oligodendrocytes sont appelés oligodendrogliomes. Il existe aussi des gliomes mixtes où les deux types de cellules sont atteintes. On les classe aussi selon leur degré de sévérité : les gliomes de grade I sont des gliomes bénins, majoritairement diagnostiqués chez les enfants. Les gliomes de grade II correspondent à des tumeurs de croissance lente mais qui évoluent généralement avec le temps vers une forme maligne et qui peuvent s'apparenter à une maladie précancéreuse. Enfin, les gliomes de grade III (ou gliomes anaplasiques) et les gliomes de grade IV (ou glioblastomes) sont systématiquement des tumeurs malignes dont le pronostic est réservé : à eux seuls, les glioblastomes représentent la majorité des gliomes et approximativement 20% des tumeurs primitives cérébrales. [20]

- **Les méningiomes** représentent environ 30% des tumeurs cérébrales primitives : ce sont des tumeurs qui se développent à partir de cellules des méninges, en superficie du cerveau. Elles sont plus fréquentes chez les femmes. Dans l'immense majorité des cas, il s'agit de tumeurs bénignes. [20]
- **Les médulloblastomes** sont des tumeurs malignes qui se développent dans le cervelet. Ils touchent essentiellement l'enfant chez qui ils représentent la tumeur cérébrale la plus fréquente, soit environ 30% d'entre elles. [20]
- **Les neurinomes** (appelés aussi schwannomes) sont des tumeurs bénignes qui représentent environ 8% des cas de tumeurs primitives de l'encéphale. Ils se développent à partir des cellules qui forment une gaine autour des nerfs (appelées cellules de Schwann) et touchent le plus souvent les nerfs de l'audition (on parle alors de neurinome de l'acoustique).
- **Les lymphomes primitifs** du système nerveux central sont des tumeurs infiltrantes qui naissent dans le cerveau à partir de certaines cellules sanguines appelées lymphocytes et ayant un rôle dans l'immunité. Ils touchent de préférence les personnes âgées ou immunodéprimées. Beaucoup d'autres tumeurs cérébrales plus rares existent comme par exemple les épendymomes, gangliogliomes, neurocytomes, pinéalomes, germinomes, craniopharyngiomes hémangiopéricytomes, hémangioblastomes... Ces tumeurs peuvent être bénignes ou malignes et affectent différents tissus ou types cellulaires du système nerveux central. [20]

## **1.5 Les Causes des tumeurs du cerveau**

Les causes des tumeurs du cerveau sont mal connues. On ne sait pas pourquoi, à un moment donné, les cellules se multiplient de manière incontrôlée jusqu'à former une tumeur. De nombreuses études scientifiques ont été menées ou sont en cours, pour tenter de déterminer les facteurs qui favorisent l'apparition d'une tumeur au niveau du cerveau. On parle de facteurs de risques. Trois types de facteurs de risques sont étudiés : les risques liés à l'environnement, à l'hérédité et aux virus.

Un facteur de risque n'explique pas à lui seul pourquoi une tumeur est apparue. En effet pour deux personnes confrontées au même risque, l'une peut développer une tumeur et l'autre non. À l'inverse, une personne peut être atteinte d'une tumeur alors qu'elle n'est concernée par aucun facteur de risque. [21]

### **Les risques liés à l'environnement**

Les études scientifiques cherchent depuis plusieurs années à déterminer l'influence de l'environnement dans l'apparition des tumeurs du cerveau. Ces études portent principalement sur :



- l'influence de certaines substances chimiques, comme les pesticides.
- les conséquences de l'exposition à des champs électromagnétiques, comme les téléphones portables, les lignes à haute tension ou certains appareils électroménagers.

- **Les substances chimiques**

Plusieurs substances chimiques sont reconnues comme cancérigènes, c'est-à-dire pouvant favoriser la survenue d'une tumeur cancéreuse du cerveau.

Il s'agit de substances chimiques utilisées dans différentes activités professionnelles, telles que la fabrication de caoutchouc synthétique et de certains médicaments, la production de polyvinyle, de pétrole brut et de produits dérivés du pétrole, l'industrie nucléaire et l'armement, et enfin la manipulation de pesticides.

Ces substances présentent un risque pour les personnes qui y sont exposées à des doses élevées et pendant une longue durée. [21]

- **Les champs électromagnétiques**

Le risque lié à l'exposition régulière à des champs électromagnétiques est encore en cours d'évaluation. Les spécialistes n'ont pas clairement déterminé si cette exposition peut entraîner des tumeurs du cerveau. Quant à l'utilisation de téléphones portables, un principe de précaution s'impose, les études ne sont pas définitivement tranchées, mais elles vont dans le sens d'un risque possible en particulier chez l'enfant et l'adolescent. Par précaution, il est donc conseillé de limiter l'utilisation du téléphone portable et de ne pas le garder sur soi. Pendant les communications, l'utilisation d'oreillettes est recommandée. [21]

### **Les risques liés à l'hérédité**

La grande majorité des tumeurs du cerveau n'ont aucun lien héréditaire. Ce n'est pas parce qu'une personne a une tumeur du cerveau que les autres membres de sa famille ont un risque accru de développer le même type de tumeur. [21]

Un risque héréditaire existe néanmoins pour deux types de tumeurs du cerveau : le neurinome et le neurofibrome. Ces tumeurs représentent moins de 5% de l'ensemble des tumeurs du cerveau. Ce sont des tumeurs bénignes, qui se développent sur le nerf auditif reliant le cerveau et l'oreille. Ces tumeurs sont souvent liées à une maladie génétique appelée neurofibromatose. La neurofibromatose n'entraîne pas systématiquement une tumeur du cerveau.

Si vous êtes atteint, des examens spécifiques peuvent vous être proposés, ainsi qu'aux membres de votre famille. Ces examens détermineront si vous avez ou non un risque de développer une tumeur. [21]

## **Les risques liés à des virus**

Selon les études scientifiques actuelles, il n'y a pas de lien entre les virus et l'apparition d'une tumeur. Seul le virus du sida (le VIH), qui affaiblit les défenses de l'organisme, peut favoriser de façon indirecte l'apparition d'une tumeur appelée lymphome du cerveau. [21]

## **1.6 Les symptômes et le diagnostic des tumeurs du cerveau**

### **1.6.1 Les symptômes possibles**

Les signes et symptômes décrits ci-dessous ne sont pas nécessairement annonciateurs d'une tumeur, ils peuvent avoir bien d'autres causes. [22]

#### **1.6.1.1 Tumeur du cerveau**

Les symptômes d'une tumeur du cerveau sont dus à la pression exercée sur les tissus cérébraux. Ils dépendent bien plus de la localisation de la tumeur et de la rapidité de croissance que de sa nature. L'analyse des troubles fonctionnels subis permet généralement de localiser la tumeur. Les symptômes ont tendance à se manifester graduellement chez les adultes tandis qu'ils peuvent survenir plutôt brusquement chez les enfants.

- Maux de tête survenant: souvent durant la nuit ou aux premières heures du matin. La plupart du temps, ces douleurs sont nouvelles et différentes des maux de tête habituels.
- nausées et vomissements dus à la pression dans la boîte crânienne.
- perte d'appétit.
- vertiges et troubles de l'équilibre.
- troubles de la vision: scintillements, perturbation du champ visuel ou perception d'images dédoublées.
- hallucinations visuelles, auditives ou olfactives.
- troubles de l'élocution et difficulté pour trouver ses mots.
- changements d'humeur, de comportement et de personnalité.
- difficultés d'apprentissage et de raisonnement.
- crises d'épilepsie. [22]

#### **1.6.1.2 Tumeur à la moelle épinière**

En fonction de l'emplacement de la tumeur, les symptômes suivants peuvent apparaître:

##### **- Douleur**

- Douleurs dans le thorax pour les tumeurs localisées au niveau de la poitrine.
- douleurs au cou, aux bras, au dos ou aux jambes pour les tumeurs situées dans le cou ou le dos.

**- Faiblesse des membres ou du tronc**

- Engourdissements, picotements, incapacité à ressentir les variations de température.
- spasmes musculaires.
- perte de contrôle des intestins ou de la vessie.
- impuissance. [22]

**1.6.2 Le Diagnostic**

Le médecin traitant joue un rôle important dans le diagnostic, car c'est souvent lui qui est consulté en premier. En cas de suspicion de tumeur, l'intervention de plusieurs médecins spécialistes est ensuite indispensable : neurologue, neurochirurgien, neuro-oncologue radiologue, anatomopathologiste (appelé aussi pathologiste)... [21]

Le diagnostic d'une tumeur du cerveau se fait en plusieurs étapes :

- un examen clinique et neurologique complet.
- des examens d'imagerie.
- un examen anatomopathologique, qui consiste à analyser un échantillon de tumeur.

**1.6.2.1 L'examen clinique et neurologique**

L'examen clinique et neurologique est réalisé au cours d'une consultation médicale, soit par le médecin traitant, soit par un médecin spécialiste du cerveau. Il consiste à évaluer l'état de santé général d'une part et le bon fonctionnement du système nerveux d'autre part.

Le médecin pose des questions sur les symptômes ressentis, les antécédents médicaux personnels, familiaux et chirurgicaux, ainsi que sur l'état de santé général. Il examine l'ensemble du corps (tension artérielle, battements du cœur, etc.), puis évalue le fonctionnement du système nerveux grâce à différents tests : [21]

- des exercices musculaires (marcher, serrer la main, sourire pour vérifier le bon fonctionnement des muscles du visage...).
- un test des réflexes.
- un test de sensibilité (sensation au toucher, réaction au chaud et au froid ou à une légère piqûre...).
- un test d'équilibre et de coordination des mouvements.
- un examen de la vue, des pupilles, des mouvements des yeux et du fond de l'œil.
- un test d'audition.
- un test de langage (capacité à trouver le bon mot par exemple), de lecture, d'écriture ou de dessin.
- des exercices mentaux (calculs simples), tests de mémoire, de compréhension, etc.

L'examen clinique et neurologique permet de constater d'éventuelles anomalies. Pour déterminer si ces anomalies sont dues à une tumeur ou non, des examens d'imagerie sont indispensables. [21]

### **1.6.2.2 Les examens d'imagerie**

Les examens d'imagerie consistent à réaliser des images précises du cerveau. Ils permettent de détecter une tumeur, de la localiser de façon précise, de mesurer sa taille et d'évaluer les conséquences qu'elle a ou peut avoir sur le cerveau. Pour le diagnostic d'une tumeur du cerveau, une IRM est indispensable. Pour des raisons pratiques, l'IRM est souvent précédée d'un scanner. [21]

- **Un scanner**

Un scanner est un examen qui permet d'obtenir des images du cerveau en coupe, grâce à un appareil qui projette des rayons X au niveau du crâne. L'appareil est constitué d'un lit d'examen et d'un gros anneau. Vous êtes allongé sur la table d'examen et votre tête est placée à l'intérieur de l'anneau. Un faisceau de rayons X dirigé sur le crâne permet d'obtenir plusieurs centaines de radiographies.

Les radiographies sont transmises à un ordinateur, qui reconstitue des images du cerveau dans les trois dimensions. Généralement, un produit de contraste à base d'iode est injecté avant ou pendant l'examen. Ce produit permet de mettre en évidence certains aspects du cerveau, notamment les vaisseaux sanguins et facilite l'interprétation des images. L'examen dure environ 15 minutes. Il n'est pas douloureux. [21]



**Figure 1.9** – Scanner du cerveau. [21]

L'utilisation de rayons X et l'injection d'iode nécessitent quelques précautions d'emploi notamment en cas d'allergie à l'iode, de grossesse, d'insuffisance rénale ou de prise de metformine (un médicament utilisé pour traiter le diabète). Il est important de signaler au médecin si vous êtes dans l'une de ces situations. [21]

- **Une IRM**

Une IRM (imagerie par résonance magnétique) est réalisée grâce à un grand appareil en forme de cylindre. Cet appareil est composé d'un aimant très puissant (d'où le terme de magnétique). Il produit des ondes radio qui sont projetées sur le cerveau et permettent d'obtenir des images « en coupe ».

Les images sont ensuite assemblées par un ordinateur pour obtenir une reproduction très précise du cerveau. Pendant l'examen, un produit de contraste est injecté dans une veine du bras, il permet de mettre en évidence certains aspects du cerveau, comme les vaisseaux sanguins et facilite l'interprétation des images, l'examen dure généralement entre 15 et 30 minutes. Il n'est pas douloureux, mais bruyant, en raison du champ magnétique, vous devez enlever tout objet métallique avant de réaliser une IRM.

Certains implants métalliques sont des contre-indications à l'examen: pacemaker, prothèse auditive, valve cardiaque mécanique, pompe à insuline...Signalez-les au médecin avant l'examen. [21]



**Figure 1.10** – IRM du cerveau. [21]

Contrairement au scanner, vous entrez presque en entier à l'intérieur de l'appareil, en position allongée. Un médicament contre l'anxiété peut être prescrit aux personnes souffrant de claustrophobie. Pour les enfants les plus jeunes, l'IRM est réalisée sous anesthésie générale pour éviter qu'ils ne bougent pendant l'examen. Une IRM n'utilise pas de rayons X.

Les résultats du scanner et de l'IRM sont généralement disponibles immédiatement après l'examen et transmis au médecin spécialiste. [21]

### **1.7 Imagerie par résonance magnétique (IRM)**

L'imagerie par résonance magnétique (IRM) constitue une des avancées les plus significatives en médecine; elle est issue des travaux sur les propriétés magnétiques des noyaux des atomes menés par F. Bloch et E. Purcell en 1946, elle constitue une technique privilégiée pour l'observation in vivo des structures anatomiques cérébrales et de leurs pathologies. Soulignons que cette technique a été tout récemment récompensée au travers du prix Nobel de Médecine 2003 attribué à P. Lauterbur et P. Mansfield, à l'origine de l'utilisation du phénomène de résonance magnétique en imagerie médicale et au travers du prix Nobel de Physique 2003 attribué à A. Abrikosov et V. Ginzburg pour leurs travaux sur les supraconducteurs. [23]

L'imagerie par résonance magnétique (IRM) est un examen d'imagerie médicale qui aide au diagnostic du cancer, à l'évaluation de l'efficacité d'un traitement ou au suivi après la fin des traitements. Une IRM permet d'obtenir des images précises de l'intérieur du corps grâce à l'utilisation d'un aimant et d'ondes électromagnétiques. Cet examen est utilisé pour examiner n'importe quelle partie du corps : les organes (tels que le cerveau, le foie, les poumons, le pancréas par exemple), mais aussi les vaisseaux sanguins, la moelle épinière, les os et les articulations. [27]

L'appareil d'IRM est constitué d'un tunnel d'environ 1,60 mètre de long, entouré d'un aimant puissant. Pendant l'examen, vous êtes allongé sur un lit (ou table d'examen) qui se déplace à l'intérieur de ce tunnel, pour positionner la zone de votre corps à examiner au centre de l'aimant. L'appareil d'IRM émet des ondes électromagnétiques qui font « vibrer » les atomes d'hydrogène composant votre corps. Ces atomes émettent des signaux qui sont captés par une antenne placée autour de la région à étudier. Enfin, les signaux sont assemblés par un ordinateur pour reconstituer des images en 2 ou 3 dimensions qui seront interprétées par un radiologue. L'injection d'un produit dit « de contraste » dans la circulation sanguine est souvent nécessaire pour améliorer la visibilité de certains organes et la détection des anomalies. [27]

### 1.7.1 Une IRM, comment ça marche ?

L'imagerie par résonance magnétique (IRM) utilise un aimant très puissant qui fait « vibrer » les atomes d'hydrogène, éléments qui composent les molécules d'eau de notre corps. Notre organisme est constitué de plus de 65 % d'eau. Au centre de chaque atome d'hydrogène se trouve une particule encore plus petite appelée proton : c'est cette particule qui est à l'origine du phénomène. Une antenne placée autour de la région à examiner va capter les « vibrations » des protons, les protons « vibrent » à des vitesses variables, selon le type de tissu dans lequel ils se trouvent. Cela permet de bien distinguer les différentes structures de l'organisme sur les images obtenues, dont les tumeurs par exemple. L'injection d'un produit de contraste est souvent nécessaire pendant l'examen afin de mieux visualiser la zone à examiner. [27]

Les signaux reçus des millions de protons dans le corps sont réunis pour créer des images en coupes détaillées de l'intérieur du corps. Des images en 2 ou 3 dimensions sont ensuite reconstituées par un ordinateur avant d'être interprétées par un radiologue. [27]

La figure ci-dessous (Figure 1.11) nous montre le processus général d'acquisition d'images.

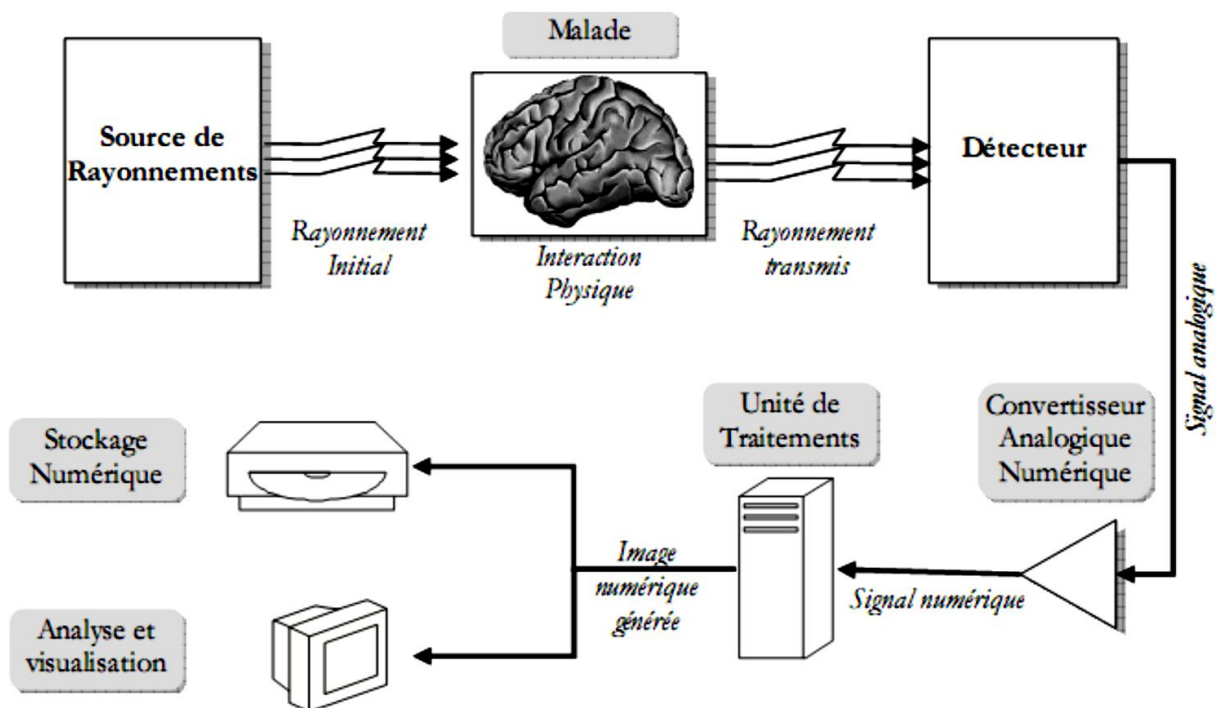


Figure 1.11 - Principe général d'un système informatisé d'imagerie. [24]

### **1.7.2 Que faut-il signaler au médecin et lors de la prise de rendez-vous ?**

Si vous êtes porteur d'un dispositif interne métallique ou électronique, il est impératif de l'indiquer au médecin qui vous prescrit l'examen, ainsi que lors de la prise de rendez-vous. En effet, le port de ce type de dispositif peut, dans certains cas, être une contre-indication à la réalisation d'une IRM. La force magnétique dégagée durant cet examen est puissante et pourrait endommager ou déplacer les dispositifs métalliques et dérégler les dispositifs électroniques. Dans ce cas, un autre type d'examen peut vous être prescrit. [27]

Vous devez également indiquer si :

- vous êtes allergique à certains médicaments ou produits de contraste.
- vous êtes enceinte, pensez l'être ou si vous allaitez.
- vous avez des antécédents de maladie ou de chirurgie des reins, souffrez de diabète d'asthme ou d'une autre maladie chronique pour laquelle vous prenez un traitement régulier.
- vous souffrez de claustrophobie.
- vous êtes tatoué (certaines encres de tatouage utilisent des oxydes de fer qui peuvent brûler la peau pendant l'IRM). [27]

### **1.7.3 Comment se préparer le jour de l'IRM ?**

Suivez attentivement les consignes de préparation qui vous ont été communiquées lors de la prise de rendez-vous et/ou par courrier. Sauf avis médical contraire, le jour de l'examen vous pouvez manger, boire et prendre vos médicaments selon vos habitudes. Dans certains cas, il faut être à jeun, c'est-à-dire ne pas avoir mangé, bu, ni fumé au moins 4 heures avant l'IRM. Dans d'autres cas, il pourra vous être demandé au contraire de boire de l'eau avant l'examen. D'autres consignes pourront également vous être données. Cela dépend de la partie du corps qui doit être examinée à l'IRM. Choisissez une tenue confortable, de préférence sans boutons-pressions ni fermeture métallique. Évitez également les vêtements en tissu synthétique, qui peuvent perturber les images. Venez sans pinces à cheveux métalliques, ni bijoux ou piercings. N'appliquez pas de pommades, de déodorants ou de maquillage sur la région à examiner. [27]

### **1.7.4 Comment se déroule une IRM ?**

L'examen complet dure 1 heure 30 en moyenne (accueil, préparation, examen surveillance et rendu des images) dont 15 à 45 minutes pour la réalisation de l'IRM en elle-même, selon l'étendue de la zone à visualiser et l'utilisation de produit de contraste.



À votre arrivée, un manipulateur en électroradiologie médicale vous questionne sur votre état de santé (antécédents, maladies, traitements en cours, port d'un dispositif interne) et vous explique le déroulement de l'examen. [27]

Ensuite, vous êtes accompagné dans une cabine de préparation pour y déposer les accessoires et objets magnétiques ou contenant du métal (montre, bijoux, ceinture, clés, porte-monnaie, cartes de crédit ou de transport, téléphone portable, prothèses dentaires, appareils auditifs externes, perruques, etc.) et, si besoin, revêtir la blouse en tissu ou en papier qui vous est remise. Lorsque l'injection d'un produit de contraste est nécessaire, un cathéter est posé au niveau du pli du coude ou du dos de la main. Il s'agit d'un petit tube en plastique souple placé dans une veine à l'aide d'une aiguille. Vous êtes ensuite accompagné en salle d'examen. [27]

L'appareil d'IRM est contrôlé à l'aide d'un ordinateur par un manipulateur en électroradiologie médicale installé derrière une vitre, dans une autre pièce. Pendant l'IRM vous êtes seul dans la salle. Néanmoins, la personne en charge de votre examen vous surveille en permanence. Un micro et une sonnette vous permettent de communiquer avec elle pendant toute la durée de l'examen et elle peut intervenir à tout moment. Pendant l'examen, vous êtes allongé sur un lit qui se déplace à l'intérieur du tunnel de l'IRM qui est éclairé et ventilé. Selon la partie du corps à examiner, vous entrez dans l'appareil la tête ou les pieds en premier.

L'appareil émet des bruits intermittents et répétitifs de martèlement qui peuvent être désagréables, pour atténuer ces bruits, le manipulateur en électroradiologie médicale vous fournit des protections auditives ou un casque pour écouter de la musique. Si vous avez froid dans la salle d'examen, vous pouvez demander une couverture. Il est très important de rester immobile toute la durée de l'examen. En fonction de la zone à examiner, il pourra vous être demandé de retenir votre respiration quelques secondes. À la fin de l'examen, vous regagnez la cabine pour vous rhabiller puis rejoignez la salle d'attente. Après un temps de surveillance nécessaire pour s'assurer de l'absence de réaction allergique, le cathéter qui a été placé pour l'examen est retiré et la zone comprimée pendant quelques minutes afin d'éviter la formation d'ecchymoses, couramment appelées « bleus ». [27]

### **1.7.5 Le principe physique de l'IRM**


La technique de l'IRM exploite les propriétés magnétiques des éléments constitutifs de la matière et se fonde sur les phénomènes physiques de résonance et de relaxation. [23]

• **Moment magnétique des noyaux**

L'existence du moment magnétique des noyaux a été montrée simultanément par Bloch et Purcell. Le corps humain étant constitué en moyenne de 70% d'eau, on s'intéresse en pratique à la molécule d'eau et en particulier au noyau d'hydrogène (proton).


Le noyau d'hydrogène se comporte comme une charge en rotation autour de son axe : c'est le mouvement de spin (figure 1.12). Les protons peuvent alors être assimilés à des dipôles magnétiques.

En l'absence de tout champ magnétique, ceux-ci vont s'orienter dans l'espace de façon aléatoire. Ce mouvement confère au noyau un moment cinétique qui dépend de sa masse et un moment magnétique qui dépend de sa charge. [23]



**Figure 1.12** - Le mouvement de spin. [23]

Dans un champ magnétique  $B_0$ , les protons s'orientent alors par rapport à  $B_0$  et décrivent autour de ce champ un mouvement de précession, de vitesse angulaire constante. L'ensemble des protons s'orientant dans le sens de  $B_0$  forme alors une sous-population de spins  $+1/2$  l'ensemble s'orientant dans le sens inverse forme la sous-population de spins  $-1/2$ . La sous-population de spins  $+1/2$  étant la plus importante, il existe une aimantation résultante  $M_0$  proportionnelle au nombre de protons présents.  $M_0$  ne possède qu'une composante longitudinale, dans le sens de  $B_0$  (figure 1.13). [23]



**Figure 1.13** - Mouvement de précession d'un ensemble de moments magnétiques. [23]


• **Phénomènes de résonance et de relaxation**

Les phénomènes de résonance et de relaxation sont liés au principe énergétique de la matière. Lorsque des protons, placés dans un champ magnétique, reçoivent un apport d'énergie sous la forme d'ondes radiofréquences de pulsation égale à leur fréquence de résonance et émises par un champ magnétique  $B_1$ , ils passent d'un niveau bas d'énergie à un niveau haut d'énergie ; cette transition correspond au phénomène de résonance magnétique.

L'orientation du champ magnétique résultant change et passe à un nouvel état d'équilibre  $M$  tant que  $B_1$  dure. On décompose alors  $M$  en un moment magnétique longitudinal  $M_L$  et en un moment magnétique transversal  $M_T$ . Le retour à l'équilibre des protons, la relaxation, lors de la disparition du champ magnétique  $B_1$ , s'accompagne d'un mouvement en spirale des protons autour du champ magnétique  $B_0$ . Bloch a montré que l'évolution de ce mouvement est liée au temps de relaxation longitudinal  $T_1$  et au temps de relaxation transversal  $T_2$  (figure 1.14). Les valeurs de ces derniers dépendent des tissus biologiques rencontrés (tableau 1.2). [23]

	<b>T<sub>1</sub></b>	<b>T<sub>2</sub></b>
<b>liquide céphalo-rachidien</b>	2500 ms	2000 ms
<b>matière grise</b>	900 ms	90 ms
<b>matière blanche</b>	750 ms	80 ms
<b>graisse</b>	300 ms	40 ms


**Tableau 1.2** - Ordre de grandeur des temps de relaxation à 1.5 Tesla. [23]



**Figure 1.14** - Décomposition du moment magnétique  $M$  en un moment transversal  $M_T$  et longitudinal  $M_L$  lors de la résonance. [23]

### **1.7.6 La formation des images IRM**

Pour constituer une image IRM, on soumet le patient à un champ magnétique  $B_0$  et à une onde radiofréquence  $B_1$  de fréquence égale à la fréquence de précession des protons. Sous l'effet de cette onde, les protons basculent d'un angle  $\alpha$ , généralement de  $90^\circ$  ou de  $180^\circ$  par rapport à  $M_0$ . À l'arrêt de l'impulsion, le retour à l'équilibre s'établit : il y a réduction rapide du moment transversal  $M_T$  et repousse du moment longitudinal  $M_L$ . Pendant ce retour à l'équilibre, le proton continue à précesser et induit un champ magnétique FID (Free Induction Decay). C'est ce signal qui est recueilli par les bobines de réception puis transformé en signal électrique (figure 1.15). [23]



**Figure 1.15** - Signal FID recueilli par les bobines réceptrices. [23]


L'image numérique IRM représente ainsi la répartition spatiale d'une grandeur physique chaque élément d'une coupe correspond à la représentation de l'aimantation nucléaire d'un volume de l'espace exploré. Ces éléments sont habituellement appelés pixels quand on considère individuellement une coupe et voxels quand on considère le volume constitué de l'empilement des coupes. [23]

La problématique liée au codage de l'image est alors de savoir différencier les signaux issus des différentes zones examinées. Ce codage est réalisé grâce au couplage de trois gradients différents :

- le gradient de coupe sélective sélectionne le plan de coupe, celui-ci pouvant être quelconque dans l'espace.
- le gradient de codage de phase sélectionne les lignes dans le plan de coupe sélectionné.
- le gradient de fréquence sélectionne les colonnes dans le plan de coupe sélectionné.

L'orientation des coupes, qui dépend en particulier du gradient de coupe sélective, varie en fonction de la pathologie recherchée.

On retrouve cependant trois orientations principales : axiale, coronale et sagittale (figure 1.16). [23]




**Figure 1.16** - Plans axial, coronal et sagittal (de gauche à droite) sur une acquisition en  $T_1$ . [23]

### 1.7.7 Les différentes pondérations

Nous pouvons identifier les paramètres qui influencent le contraste de l'image IRM en deux grandes classes :

- La première est constituée de paramètres intrinsèques liés directement aux tissus observés. Il s'agit de la densité en protons  $\rho$ , des temps de relaxation  $T_1$  et  $T_2$ , de la présence d'un agent de contraste ou encore de la vitesse des fluides circulant.
- La seconde est constituée de paramètres liés à l'appareil lui-même (en particulier l'intensité et la constance du champ magnétique  $B_0$ ) et à la séquence d'acquisition. Cette dernière dépend essentiellement du temps de répétition  $T_R$  séparant deux impulsions de l'onde radiofréquence  $B_1$  et du temps d'écho  $T_E$  séparant l'impulsion de la lecture du signal. Parmi les séquences classiques, on distingue les séquences spin écho, écho gradient et inversion- récupération.

Parmi ces paramètres, seuls les paramètres d'acquisition sont modulables et conduisent à l'obtention d'images dites « pondérées en  $T_1$  », « pondérées en  $T_2$  » ou encore « pondérées en  $\rho$  ». (Figure 1.17). [23]



(a) pondération en  $T_1$

(b) pondération en  $T_2$

(c) pondération en  $\rho$

**Figure 1.17** - Une même coupe obtenue sous différents paramètres d'acquisition. [23]

**- Image pondérée en  $T_1$**

Pour des  $T_R$  de l'ordre de 600 ms, le contraste entre les tissus dépend essentiellement de leur vitesse d'aimantation, donc de  $T_1$ . Pour des  $T_E$  d'environ 20 ms, les différences de décroissance du signal entre les tissus n'ont pas le temps de s'exprimer, rendant le contraste indépendant de  $T_2$ . Ainsi, on obtient une image pondérée en  $T_1$ , où les tissus sont ordonnés par niveaux de gris croissants en liquide céphalo-rachidien, matière grise puis matière blanche. [23]

**- Image pondérée en  $T_2$**

Pour des  $T_R$  de l'ordre de 2 s et des  $T_E$  d'environ 90 ms, la décroissance du signal domine la différence de densité protonique entre tissus. Le signal est alors suffisant pour réaliser une image dite pondérée en  $T_2$ , où les tissus sont ordonnés par niveaux de gris croissants en matière blanche, matière grise puis liquide céphalo-rachidien.

**- Image pondérée en densité de protons  $\rho$**

Pour un  $T_R$  de l'ordre de 2 s et un  $T_E$  court d'environ 20 ms, la différence de densité protonique entre la matière grise et la matière blanche s'exprime. On obtient une séquence qui reflète la localisation et la concentration des noyaux d'hydrogène des différentes structures. Les tissus sont ordonnés par niveaux de gris croissants en matière blanche, matière grise puis liquide céphalo- rachidien. [23]


**- Influence du produit de contraste Gadolinium**

L'injection de gadolinium présente un intérêt majeur dans le diagnostic des tumeurs cérébrales. En effet, sans ce produit de contraste, une image peut ne pas refléter la présence de la tumeur. La fixation du gadolinium, en modifiant les propriétés magnétiques des éléments transforme leur réponse au champ radiofréquence en raccourcissant le  $T_1$  et en créant de l'hyper- signal 2 (figure 1.18). En  $T_2$ , l'injection de gadolinium soit ne modifie pas le contraste des lésions, soit, à de fortes concentrations, « éteint » l'hyper-signal spontané. [23]

Même si le gadolinium permet la création d'un hyper-signal au niveau de la tumeur, il faut néanmoins utiliser cette information avec prudence. D'une part, l'hyper-signal ne peut s'exprimer qu'aux endroits où le gadolinium a circulé; or, certaines tumeurs sont partiellement ou totalement imperméables à ce produit (figure 1.18-b). D'autre part l'injection de gadolinium sous-estime le volume de la lésion. Dans ces deux cas, on mesure donc l'intérêt de réaliser une acquisition en  $T_2$  complémentaire.

Ces deux cas représentent une coupe pondérée en  $T_1$  et la même après injection de gadolinium. Dans le premier cas, le gadolinium a parfaitement rehaussé la tumeur. Dans le second, seule une partie de la tumeur est mise en évidence. Ceci illustre à la fois l'intérêt

d'une acquisition après injection du produit de contraste mais aussi la prudence qu'il faut observer lors de l'analyse des clichés. [23]



**Figure 1.18** - Intérêt d'une acquisition avec injection de gadolinium. [23]

L'utilisation conjointe des différentes pondérations d'acquisition est particulièrement intéressante dans le cadre du diagnostic des lésions cérébrales. En effet, il est fréquent qu'une tumeur n'apparaisse que partiellement sur une image. La solution adoptée est alors de multiplier les acquisitions et les pondérations utilisées et éventuellement de faire des acquisitions sous-produit de contraste de manière à compléter successivement l'information sur le processus recherché, chaque pondération, qui apporte ainsi une part d'information complémentaire, mais aussi redondante, peut ainsi être considérée comme une observation particulière de la zone cérébrale. Notons que ces observations peuvent parfois être conflictuelles, par exemple lorsque qu'une tumeur est complètement absente sur une pondération et apparaît sur une autre. L'utilisation conjointe par les médecins de l'ensemble des images, leur permet de synthétiser l'information et ainsi d'avoir une information plus complète sur la zone tumorale. [23]

### 1.7.8 Défauts des images IRM (artefacts)

Outre les trois paramètres principaux qui entrent en jeu dans la formation d'une image de résonance magnétique, un certain nombre d'autres facteurs viennent affecter la qualité des images. Les erreurs (artefacts) d'acquisitions en IRM sont de natures différentes de celles observées dans d'autres domaines du traitement d'images.

On distingue essentiellement quatre effets: le bruit, le mouvement, les variations de champ et les effets de volume partiel. [28]

- **Bruit**

Le bruit a des origines multiples, liées en partie au bruit de l'appareillage, dans les images par résonance magnétique, l'objectif est d'augmenter le contraste entre les tissus tout en conservant une bonne résolution et un rapport signal/bruit élevé, ces caractéristiques sont cependant contradictoires et il est nécessaire de trouver un bon compromis entre résolution et bruit. Ainsi, on peut doubler la taille des pixels pour multiplier le rapport signal/bruit d'un facteur  $p$ , mais la résolution est divisée par deux. Le choix d'acquisitions est donc un facteur déterminant.

- **Mouvement**

Le mouvement peut provenir de plusieurs sources. Il peut être lié au métabolisme comme la circulation sanguine ou la respiration (déplacement chimique), il peut également être lié au mouvement du patient pendant l'acquisition. Dans tous les cas, le mouvement diminue la qualité de l'image et pose des problèmes d'interprétation, les mouvements de la tête, sont responsables d'artefacts dans les IRM cérébrales. [24]

- **Variations du champ magnétique (inhomogénéité RF : Radio Fréquence)**


Les variations de champ ont pour conséquence une variation des intensités d'un même tissu dans une direction quelconque de l'image. Ce phénomène est dû au fait que le champ magnétique n'est pas parfaitement homogène spatialement et temporellement pendant une acquisition. Il existe de plus des non-linéarités de gradient de champ magnétique.

Des approches ont été proposées pour corriger les inhomogénéités du champ magnétique dans le cadre de prétraitements. Les distorsions de champ sont également analysées en détail et corrigées. [24]

- **Effets de volume partiel**

Les effets de volume partiel sont directement liés au processus de numérisation du signal. Ainsi, si un pixel intersecté plusieurs objets, son niveau de gris sera une combinaison des niveaux de gris issus de chacun des objets traversés. La prise en compte des effets de volumes partiels est nécessaire dans le cadre d'approches de segmentation dont l'objectif est d'effectuer des mesures sur les différents tissus. Cet artefact n'est pas très gênant pour le clinicien sauf dans des cas extrêmes, où le contraste entre différents tissus disparaît par exemple (Figure 1.19). [24]





**Figure 1.19** - L'inhomogénéité RF.

(a) Image affectée par une inhomogénéité RF, (b) L'artefact RF isolé, (c) Image sans artefact. [24]

### 1.7.9 Avantage des images IRM

L'étude du cerveau a connu un développement impressionnant ces dernières années grâce à l'IRM. Son développement permettra d'observer le cerveau et ses pathologies avec une précision encore plus fine, à une échelle plus représentative des phénomènes qui l'animent. Elle est l'une des méthodes les plus courantes et les plus importantes pour diagnostiquer et évaluer le cerveau du patient et la croissance de nombre d'appareils IRM restent très élevées. Plusieurs atouts sont à la base de ce succès [29]:

- Un contraste excellent pour les tissus mous grâce aux temps de relaxation T1 et T2 et la densité des spins.
- Versatilité dans la modification du signal avec des agents de contraste.
- Bonne résolution spatiale (de l'ordre de 1 mm) et temporelle (de l'ordre de 50 ms pour une seule coupe à quelques minutes pour les images 3D).
- L'examen IRM peut durer jusqu'à une heure, mais La précision est plus élevée que celle du scanner. [17]

## 1.8 Conclusion

Dans ce chapitre, nous avons présenté tout ce qui concerne les tumeurs cérébrales, les notions essentielles liées à l'anatomie du cerveau et les principales régions cérébrales qui ont une importance dans l'examen et le diagnostic clinique.

Nous avons présenté également les principes d'acquisition des images médicales. Nous avons remarqué que l'imagerie à Résonance Magnétique est une technique d'imagerie médicale très utile pour l'observation du cerveau. Car c'est la méthode d'imagerie qui, dans la plupart des cas, donne les informations les plus riches (la résolution spatiale habituelle est de l'ordre du millimètre). Après avoir énoncé les principes physiques qui la régissent, nous nous sommes

successivement intéressées à la formation des images, aux différentes pondérations qu'offrent cette technique d'imagerie et leur intérêt dans le cadre du diagnostic des tumeurs cérébrales et enfin aux imperfections qui détériorent la qualité de ces images.

Dans notre travail, nous nous intéressons à la détection automatique de la tumeur cérébrale utilisant d'apprentissage en profondeur (deep learning) qui est le sujet du prochain chapitre.

# *Chapitre 2*

## *Apprentissage Profond (Deep Learning)*

### **Sommaire**

---

- 2.1 Introduction.**
  - 2.2 Généralités sur les réseaux de neurones artificiels.**
  - 2.3 Historique du deep learning.**
  - 2.4 Définition de l'apprentissage profond (Deep Learning).**
  - 2.5 Pourquoi l'apprentissage profond (DL) ?**
  - 2.6 L'importance de l'apprentissage profond (DL)**
  - 2.7 Comment fonctionne l'apprentissage profond ?**
  - 2.8 Principe de l'apprentissage profond (DL).**
  - 2.9 Classification de l'apprentissage profond.**
  - 2.10 Les différents types de modèles**
    - 2.10.1 Réseau de neurones récurrent (RNN).**
    - 2.10.2 Perceptrons multicouches.**
    - 2.10.3 Modèle génératif (deep generative model).**
    - 2.10.4 Réseaux de neurones convolutifs (CNN).**
      - 2.10.4.1 Introduction.**
      - 2.10.4.2 Définition de réseaux de neurones convolutifs.**
      - 2.10.4.3 CNN vs ANN.**
      - 2.10.4.4 Les différentes couches des CNN.**
      - 2.10.4.5 Quelques réseaux convolutifs célèbres.**
      - 2.10.4.6 Transfert Learning.**
  - 2.11 Conclusion.**
-

## 2.1 Introduction

Actuellement l'informatique est presque présente dans tous les domaines : la santé l'éducation, l'économie, et la cosmologie. Cette présence se reflète dans la vie quotidienne de l'individu et elle a permis des facilités d'utilisation et de compréhension de plusieurs complexes domaines. Un des domaines les plus importants qui a été touché par ce terrible développement de l'informatique est le domaine de la santé. Le développement de l'informatique et de la technologie continue à prendre une place de plus en plus importante dans le domaine de santé, ce qui a permis le développement du matériel médical, les logiciels de surveillance médicale, et les logiciels d'analyse médicale qui augmentent la précision des résultats. Ce dernier a donné une grande attention par les scientifiques, en particulier les spécialistes dans les domaines : de l'intelligence artificielle, les systèmes experts l'apprentissage automatique (Machine Learning) et l'apprentissage en profondeur ( Deep Learning). [7]

L'apprentissage profond est dérivé de la recherche sur le réseau neuronal artificiel. L'une des structures d'apprentissage de profondeur communes est une perception multicouche contenant plusieurs couches cachées. Le mode de travail de base de l'apprentissage profond consiste à former une caractéristique plus abstraite de haut niveau en analysant et en combinant des fonctionnalités de bas niveau, dérivant et mappage, pour montrer la catégorie d'attributs, de sorte que les caractéristiques des données ayant une représentation de fonctionnalités distribuées se trouvent à avoir une identification caractéristique des données.

L'apprentissage approfondi est devenu un nouveau domaine de la recherche sur l'intelligence artificielle et ses objectifs de recherche sont d'établir une représentation informatique d'un ordinateur similaire au cerveau humain pour analyser l'apprentissage, c'est-à-dire un réseau neuronal, qui imite la manière d'étudier les choses et Mécanismes pour expliquer les données telles que le texte de la langue, l'audio, la photographie et plus encore. L'introduction de la technologie d'apprentissage profonde est une tentative dans le domaine de la segmentation de l'image médicale. Il a un grand nombre de données à l'avance pour améliorer la précision de la segmentation. Ce nouveau type de recherche et de mise en œuvre a des prospects généraux, qui peuvent être utilisés pour corriger les erreurs dans certains segments. [8]

L'apprentissage en profondeur est un terme utilisé pour un sous-ensemble de modes d'apprentissage automatique qui utilisent plusieurs paramètres d'apprentissage de plusieurs couches, ce qui permet de créer une chaîne de fonctionnalités simples pouvant exprimer des concepts complexes. Les premières couches apprennent des fonctionnalités simples et la

représentation devient peu à peu plus complexe. Au fur et à mesure que nous nous rapprochons de la couche de sortie, une chose qui rend le deep Learning intéressant est que nous ne disons pas au modèle quelles fonctionnalités extraire à chaque couche, tout ce que nous devons faire est de fournir des paires d'entrée et de sortie. Il est donc utile de savoir comment fonctionne l'apprentissage en profondeur et comment en tirer le meilleur parti. [8]

Dans le deep learning, les grands réseaux de neurones artificiels sont alimentés par des algorithmes d'apprentissage et des quantités croissantes de données, améliorant continuellement leur capacité à "penser" et à "apprendre au fur et à mesure qu'ils traitent les données. "Deep" fait référence aux nombreuses couches que le réseau neuronal accumule dans le temps afin d'améliorer sa performance à mesure qu'il progresse dans son apprentissage. Alors que l'essentiel du deep learning s'effectue actuellement sous supervision humaine, l'objectif est de créer des réseaux neuronaux capables de s'entraîner seuls et d'apprendre en toute autonomie. [8]

## **2.2 Généralités sur les réseaux de neurones artificiels**

Le cerveau humain a une fantastique puissance de traitement de l'information si l'on considère ses capacités à prendre en charge certaines tâches nécessaires pour obtenir un comportement intelligent. La nature de l'intelligence a longtemps été un sujet difficile et controversé. D'une certaine manière, chacun a une idée assez vague de ce qu'est l'intelligence la capacité à observer, à comprendre, à se souvenir, à résoudre des problèmes, à apprendre, à créer,...etc. Deux disciplines sont concernées par la définition et la modélisation du comportement intelligent : ce sont la psychologie cognitive et l'intelligence artificielle (IA en Jargon informatique), la psychologie cognitive est l'étude scientifique des structures de mémorisation et des processus de raisonnement humain. [1]

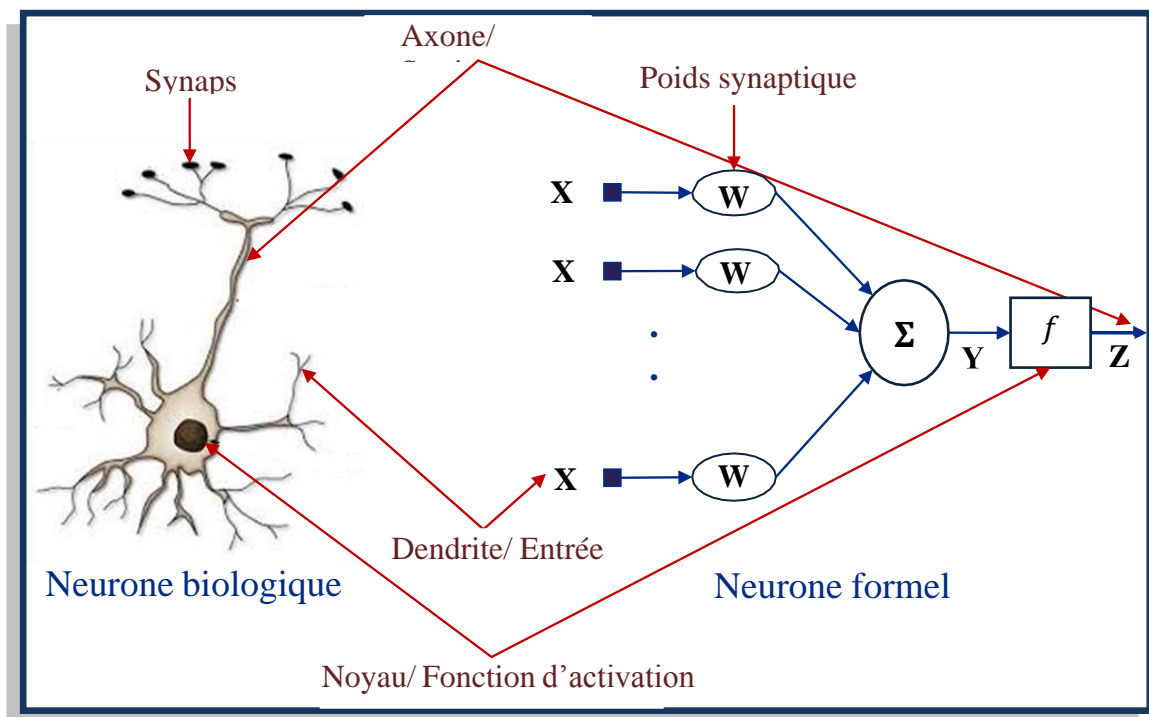
Les réseaux de neurones artificiels, nés il y a environ une cinquantaine d'années, sont toujours en cours de développement. Cet axe de recherche a tiré l'attention de beaucoup de chercheurs de différentes disciplines. Ces réseaux de neurones artificiels (RNA) sont issus de la combinaison entre la neurobiologie comme idée de base, la physique comme champs d'application et les mathématiques avec l'informatique en tant que moyens de réalisation. [30]

L'origine des réseaux de neurones vient de l'essai de modélisation mathématique du cerveau humain les premiers travaux datent de 1943 et sont l'œuvre de W.M. Culloch et W. Pitts. Ils supposent que l'impulsion nerveuse est le résultat d'un calcul simple effectué par chaque neurone et que la pensée née grâce à l'effet collectif d'un réseau de neurone interconnecté. [1]

Un réseau de neurones est un assemblage de constituants élémentaires interconnectés (appelés «neurones» en hommage à leur modèle biologique), qui réalisent chacun un traitement simple mais dont l'ensemble en interaction fait émerger des propriétés globales complexes. Chaque neurone fonctionne indépendamment des autres de telle sorte que l'ensemble forme un système massivement parallèle. L'information est stockée de manière distribuée dans le réseau sous forme de coefficients synaptiques ou de fonctions d'activation il n'y a donc pas de zone de mémoire et de zone de calcul, l'une et l'autre sont intimement liés.

Un réseau de neurone ne se programme pas, il est entraîné grâce à un mécanisme d'apprentissage. Les tâches particulièrement adaptées au traitement par réseau de neurones sont: l'association, la classification, la discrimination, la prévision ou l'estimation, et la commande de processus complexes. Les réseaux de neurones artificiels consistent en des modèles plus ou moins inspirés du fonctionnement cérébral de l'être humain en se basant principalement sur le concept de neurone. [1]

La modélisation d'un neurone formel consiste à mettre en œuvre un système de réseau de neurones sous un aspect non pas biologique mais artificiel, cela suppose que d'après le principe biologique on aura une correspondance pour chaque élément composant le neurone biologique donc une modélisation pour chacun d'entre eux. On pourra résumer cette modélisation par la figure 2.1 qui nous permettra de voir clairement la transition entre le neurone biologique et le neurone formel. [3]



**Figure 2.1** - Illustration de l'analogie entre un neurone biologique (à gauche) et un neurone formel (à droite). [4]

Un neurone est essentiellement constitué d'un intégrateur qui effectue la somme pondérée de ses entrées. Le résultat  $s$  de cette somme est ensuite transformé par une fonction de transfert  $f$  qui produit la sortie  $y$  du neurone. Les  $n$  entrées du neurone correspondent au vecteur  $x=[x_1, x_2, x_3, \dots, x_n]^T$  alors que  $w=[w_{11}, w_{21}, w_{31}, \dots, w_{n1}]^T$  représente le vecteur des poids du neurone. La sortie  $s$  de l'intégrateur est donnée par l'équation suivante : [3]

$$\begin{aligned} s &= \sum_{i=1}^n w_{i1} x_i \pm b \\ &= w_{11}x_1 + w_{21}x_2 + w_{31}x_3 + \dots + w_{n1}x_n \pm b \end{aligned} \quad (2.1)$$

L'architecture d'un réseau de neurones est l'organisation des neurones entre eux au sein d'un même réseau. Autrement dit, il s'agit de la façon dont ils sont ordonnés et connectés. La majorité des réseaux de neurones utilise le même type de neurones. Quelques architectures plus rares se basent sur des neurones dédiés. L'architecture d'un réseau de neurones dépend de la tâche à apprendre.

Un réseau de neurone est en général composé de plusieurs couches de neurones, des entrées jusqu'aux sorties. On distingue deux grands types d'architectures de réseaux de neurones : les réseaux de neurones non bouclés et les réseaux de neurones bouclés. [1]

#### ▪ Les réseaux de neurones non bouclés

Un réseau de neurones non bouclé est représenté graphiquement par un ensemble de neurones "connectés" entre eux, l'information circulant des entrées vers les sorties sans "retour en arrière" si l'on représente le réseau comme un graphe dont les nœuds sont les neurones et les arêtes les "connexions" entre eux ; le graphe d'un réseau non bouclé est acyclique. Le terme de "connexions" est une métaphore : dans la très grande majorité des applications, les réseaux de neurones sont des formules algébriques dont les valeurs numériques sont calculées par des programmes d'ordinateurs, non des objets physiques (circuits électroniques spécialisés) néanmoins, le terme de connexion, issu des origines biologiques des réseaux de neurones, est passé dans l'usage. Il a même donné naissance au terme de connexionnisme. [1]

##### - Réseaux de neurones monocouches

La structure d'un réseau monocouche est telle que des neurones organisés en entrée soient entièrement connectés à d'autres neurones organisés en sortie par une couche modifiable de poids (figure 2.2). [1]

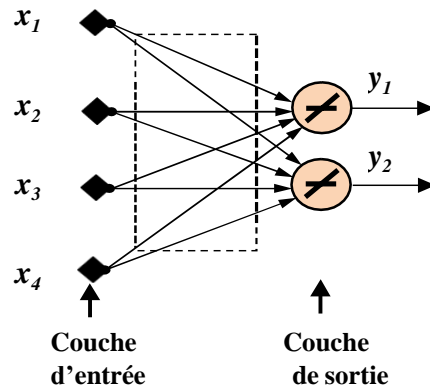


Figure 2.2 - Schéma d'un réseau de neurones monocouche. [1]

- Réseaux de neurones multicouches

Les neurones sont arrangés par couche. Il n'y a pas de connexion entre neurones d'une même couche, et les connexions ne se font qu'avec les neurones de couches avales. Habituellement, chaque neurone d'une couche est connecté à tous les neurones de la couche suivante et celle-ci seulement. Ceci nous permet d'introduire la notion de sens de parcours de l'information (de l'activation) au sein d'un réseau et donc définir les concepts de neurone d'entrée, neurone de sortie. Par extension, on appelle couche d'entrée l'ensemble des neurones d'entrée, couche de sortie l'ensemble des neurones de sortie. Les couches intermédiaires n'ayant aucun contact avec l'extérieur sont appelées couches cachées.

La figure 2.3 représente un réseau de neurones non bouclé qui a une structure particulière très fréquemment utilisée : il comprend des entrées, deux couches de neurones cachés et des neurones de sortie. Les neurones de la couche cachée ne sont pas connectés entre eux. Cette structure est appelée Perceptron multicouches. [1]




Figure 2.3 - Schéma d'un réseau de neurones non bouclé (Perceptron multicouches). [1]



### - Réseaux de neurones à connexions locales


Il s'agit d'une structure multicouche, mais qui à l'image de la rétine conserve une certaine topologie. Chaque neurone entretient des relations avec un nombre réduit et localisé de neurones de la couche avale. Les connexions sont donc moins nombreuses que dans le cas d'un réseau multicouche classique.

Les réseaux de neurones non bouclés sont des objets statiques : si les entrées sont indépendantes du temps, les sorties le sont également. Ils sont utilisés principalement pour effectuer des tâches d'approximation de fonction non linéaire, de classification ou de modélisation de processus statiques non linéaire. [1]

### ▪ Les réseaux de neurones bouclés

Contrairement aux réseaux de neurones non bouclés dont le graphe de connexions est acyclique, les réseaux de neurones bouclés peuvent avoir une topologie de connexions quelconque, comprenant notamment des boucles qui ramènent aux entrées la valeur d'une ou plusieurs sorties. Pour qu'un tel système soit causal, il faut évidemment qu'à toute boucle soit associé un retard : un réseau de neurones bouclé est donc un système dynamique, régi par des équations différentielles ; comme l'immense majorité des applications sont réalisées par des programmes d'ordinateurs, on se place dans le cadre des systèmes à temps discret, où les équations différentielles sont remplacées par des équations aux différences.

Il s'agit donc de réseaux de neurones avec retour en arrière (feedback network or recurrent network), (Figure 2.4). [1]



**Figure 2.4** - Schéma de réseau de neurones bouclé. [1]

Parmi les propriétés désirables pour un réseau de neurones, la plus fondamentale est sûrement la capacité d'apprendre de son environnement, d'améliorer sa performance à travers un processus d'apprentissage. L'apprentissage est un processus dynamique et itératif permettant de modifier les paramètres d'un réseau en réaction avec les stimuli qu'il reçoit de son environnement. Le type d'apprentissage est déterminé par la manière dont les changements de paramètre surviennent. [3]

### 2.3 Historique du deep learning


Année	Contributeur	Contribution
300 AC	Aristotle	introduction du Neural Groupings comme les premiers modèles de réseaux de neurones
1873	Alexander Bain	introduction du Neural Groupings comme les premiers modèles de réseaux de neurones
1943	1943 McCulloch and Pitts	introduction du McCulloch–Pitts (MCP) modèle considéré comme L’ancêtre des réseaux de neurones artificiels
1949	Donald Hebb	considérer comme le père des réseaux de neurones il introduit la règle d’apprentissage de Hebb qui servira de fondation pour les réseaux de neurones moderne
1958	Frank Rosenblatt	introduction du premier perceptron
1974	Paul Werbos	introduction de la retro propagation
1980	Teuvo Kohonen	introduction des cartes auto organisatrices
1982	John Hopfield	introduction des réseaux de Hopfield
1985	Hilton and Sejnowski	introduction des machines de Boltzmann
1986	Paul Smolensky	introduction d’Harmonium, qui sera connu plus tard comme machines de Boltzmann restreintes
1986	Michael I. Jordan	définition et introduction des réseaux de neurones récurrents
1990	Yann LeCun	introduction de LeNet et montra la capacité des réseaux de neurones profond
1997	Schuster and Paliwal	introduction des réseaux de neurones récurrents bidirectionnels
1997	Hochreiter and Schmidhuber	introduction de LSTM, qui ont résolu le problème du vanishing gradient dans les réseaux de neurones récurrent
2006	Geoffrey Hinton	introduction des Deep belief Network
2009	Salakhutdinov and Hinton	introduction des Deep Boltzmann Machines
2012	Alex Krizhevsky	introduction de AlexNet qui remporta le challenge ImageNet

**Tableau 2.1** – Les étapes majeurs du Deep Learning. [12]

### 2.4 Définition de l’apprentissage profond (Deep Learning)

L’apprentissage en profondeur (Deep Learning : DL) est une branche de l’apprentissage automatique qui enseigne aux ordinateurs à faire ce qui vient naturellement aux humains : apprendre de l’expérience. Les algorithmes d’apprentissage automatique utilisent des méthodes de calcul pour "apprendre" des informations directement à partir de données sans s’appuyer sur une

équation prédéterminée comme modèle. DL est une classe de techniques d'apprentissage automatique qui exploitent de nombreuses couches de traitement d'informations non linéaires pour l'extraction et la transformation de fonctions supervisées ou non supervisées, et pour l'analyse et la classification de modèles. Les caractéristiques et les concepts de niveau supérieur sont donc définis en termes de niveaux inférieurs, et une telle hiérarchie de caractéristiques est appelée architecture profonde. La plupart de ces modèles sont basés sur un apprentissage non supervisé des représentations. [8]



**Figure 2.5** – Définition de Deep Learning. [11]

## 2.5 Pour quoi l'apprentissage profond (DL) ?

L'apprentissage profond (DL) avec leurs capacités remarquables de dériver une signification des données compliquées ou imprécises, peut être utilisé pour extraire des modèles et détecter les tendances trop complexes pour être remarquées par l'homme ou techniques informatiques. Un réseau de neurones qualifiés peut être considéré comme un "expert" dans la catégorie des informations qu'il a été donné à analyser. Cet expert peut alors être utilisé pour fournir des projections nouvelles des situations d'intérêt et de réponse.

Les autres avantages incluent : [8]

1. Stockage des informations sur l'ensemble du réseau: informations tels que dans la programmation traditionnelle est stocké sur l'ensemble réseau, pas sur une base de données.
2. Capacité à travailler avec des connaissances incomplètes: après formation, les données peuvent produire une sortie même avec des informations incomplètes.
3. Avoir la tolérance aux pannes : la corruption d'une ou plusieurs cellules.
4. Avoir une mémoire distribuée : pour qu'ANN soit capable d'apprendre, il est nécessaire de déterminer les exemples et d'enseigner au réseau en fonction de la sortie souhaitée en

montrant ces exemples au réseau. Le succès du réseau est directement proportionnel aux instances sélectionnées et si l'événement ne peut pas être montré au réseau dans tous ses aspects, le réseau peut produire une fausse sortie.

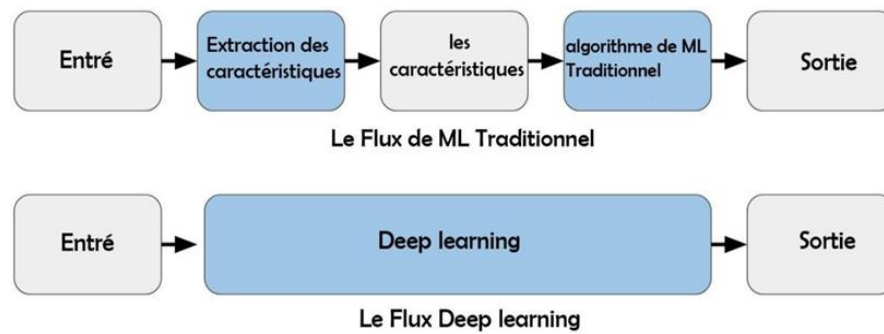
**5.** Capacité à faire apprendre à machine : les réseaux Neurons artificiels apprennent des événements et prennent des décisions en commentant les événements similaires.

**6.** Capacité de traitement parallèle: réseaux de neurones artificiels avoir une force numérique qui peut effectuer plus d'un emploi en même temps. [8]

Les algorithmes de Machine Learning ML décrits dans la première partie fonctionnent bien pour une grande variété de problèmes. Cependant ils ont échoués à résoudre quelques problèmes majeurs de l'IA telle que la reconnaissance vocale et la reconnaissance d'objets. Le développement du deep learning fut motivé en partie par l'échec des algorithmes traditionnels dans de telle tâche de l'IA. Mais ce n'est qu'après que de plus grandes quantités de données ne soit disponibles grâce notamment au Big Data et aux objets connectés et que les machines de calcul soient devenues plus puissantes qu'on a pu comprendre le potentiel réel du Deep Learning. [12]

Une des grandes différences entre le Deep Learning et les algorithmes de ML traditionnelles c'est qu'il s'adapte bien, plus la quantité de données fournie est grande plus les performances d'un algorithme de Deep Learning sont meilleurs. Contrairement à plusieurs algorithmes de ML classiques qui possèdent une borne supérieure à la quantité de données qu'ils peuvent recevoir des fois appelée "plateau de performance", les modèles de Deep Learning n'ont pas de telles limitations (théoriquement) et ils sont même allés jusqu'à dépasser la performance humaine dans des domaines comme traitement d'image. [12]

Autre différence entre les algorithmes de ML traditionnelles et les algorithmes de Deep Learning c'est l'étape de l'extraction de caractéristiques. Dans les algorithmes de ML traditionnelles l'extraction de caractéristiques est faite manuellement, c'est une étape difficile et coûteuse en temps et requiert un spécialiste en la matière alors qu'en Deep Learning cette étape est exécutée automatiquement par l'algorithme. [12]



**Figure 2.6** - Le procédé du ML classique comparé à celui du Deep Learning. [10]

## 2.6 L'importance de l'apprentissage profond (DL)

- L'apprentissage automatique fonctionne uniquement avec des ensembles de données structurées et semi-structurées, tandis que l'apprentissage en profondeur fonctionne avec des données structurées et non structurées.
- Les algorithmes d'apprentissage en profondeur peuvent effectuer efficacement des opérations complexes, tandis que les algorithmes d'apprentissage automatique ne le peuvent pas.
- Les algorithmes d'apprentissage automatique utilisent des échantillons de données étiquetés pour extraire des modèles, tandis que l'apprentissage en profondeur accepte de gros volumes de données en entrée et analyse les données d'entrée pour extraire les caractéristiques d'un objet.
- Les performances des algorithmes d'apprentissage automatique diminuent à mesure que le nombre de données augmente ; donc pour maintenir les performances du modèle, nous avons besoin d'un apprentissage en profondeur. [11]

## 2.7. Comment fonctionne l'apprentissage profond ?

Les réseaux de neurones sont des couches de nœuds, tout comme le cerveau humain est composé de neurones. Les nœuds au sein des couches individuelles sont connectés aux couches adjacentes. On dit que le réseau est plus profond en fonction du nombre de couches dont il dispose. Un seul neurone du cerveau humain reçoit des milliers de signaux d'autres neurones. Dans un réseau neuronal artificiel, les signaux voyagent entre les nœuds et attribuent des poids correspondants. Un nœud pondéré plus lourd exercera plus d'effet sur la couche de nœuds suivante. La couche finale compile les entrées pondérées pour produire une sortie. Les systèmes d'apprentissage en profondeur nécessitent un matériel puissant car ils traitent une grande quantité de données et impliquent plusieurs calculs mathématiques

complexes. Cependant, même avec un matériel aussi avancé, les calculs de formation en apprentissage profond peuvent prendre des semaines. [11]

Les systèmes d'apprentissage en profondeur nécessitent de grandes quantités de données pour renvoyer des résultats précis ; en conséquence, les informations sont alimentées sous la forme d'énormes ensembles de données. Lors du traitement des données, les réseaux de neurones artificiels sont capables de classer les données avec les réponses reçues à partir d'une série de questions binaires vraies ou fausses impliquant des calculs mathématiques très complexes. Par exemple, un programme de reconnaissance faciale fonctionne en apprenant à détecter et à reconnaître les arêtes et les lignes des visages, puis les parties les plus significatives des visages et, enfin, les représentations globales des visages. Au fil du temps, le programme s'entraîne et la probabilité de réponses correctes augmente. Dans ce cas, le programme de reconnaissance faciale identifiera avec précision les visages avec le temps. [11]

## **2.8 Principe de l'apprentissage profond (DL)**

L'apprentissage profond est constitué d'une variété de techniques issues du domaine de l'apprentissage automatique qui utilisent un déluge de nœuds non linéaires disposés en plusieurs couches qui extraient et convertissent des valeurs de variables d'entité à partir du vecteur d'entrée. Les couches individuelles d'un tel système ont en entrée les sorties des couches précédentes, à l'exception de la couche initiale d'entrée qui reçoit les signaux ou les vecteurs d'entrée de l'environnement extérieur. De plus, lors de la formation des systèmes, des techniques non supervisées ou supervisées pourraient être appliquées. Cela entraîne l'application possible de ces modèles à des tâches d'apprentissage supervisées telles que la classification et à des tâches non supervisées telles que l'analyse des modèles. [14]

Les modèles d'apprentissage approfondi reposent également sur l'extraction des entités de niveau supérieur des entités de niveau inférieur afin d'obtenir une représentation stratifiée des données d'entrée via une approche d'apprentissage non supervisée sur les différents niveaux des entités. Un classement des notions et des théories est obtenu en apprenant différentes couches de représentations des données représentant différents niveaux d'absorption des données. Certains des cadres d'apprentissage profond de la littérature sont les réseaux de croyances profondes (DBN), les réseaux d'auto-encodeurs profonds / empilés (DAE / SAE) et les réseaux de neurones convolutionnels (CNN). Ces cadres d'apprentissage profond ont été utilisés dans divers secteurs tels que le traitement du langage naturel, la reconnaissance de la parole, la reconnaissance audio la reconnaissance et la détection d'objets et la vision par

ordinateur. L'apprentissage profond est une branche des algorithmes d'apprentissage automatique qui : [14]

- utilise plusieurs couches de nœuds de traitement non linéaires pour l'extraction et la transformation d'entités. Les couches successives utilisent les sorties des couches précédentes en entrée.
- apprend de manière non supervisée (analyse de modèle, par exemple) et / ou supervisée (classification, par exemple).
- apprend plusieurs niveaux de représentations liés à différents niveaux d'abstraction. Ces niveaux représentent une hiérarchie de concepts. [14]

## **2.9 Classification de l'apprentissage profond**

L'apprentissage profond peut être classé en trois classes principales en fonction des objectifs pour lesquels elles ont été conçues:

- Les réseaux profonds d'apprentissage non supervisé ou génératif visent à capturer la corrélation d'ordre élevé des données d'entrée non étiquetées à des fins de reconnaissance ou de synthèse de modèles. Lorsqu'ils sont utilisés pour caractériser les distributions statistiques communes des données observées et de leurs classes associées, les réseaux disposent d'un mode génératif et pourraient être transformés en réseaux discriminants pour un apprentissage plus approfondi.
- Les réseaux profonds d'apprentissage supervisé sont utilisés lorsque des données d'étiquette cible sont disponibles, les modèles pouvant directement fournir un pouvoir discriminant aux fins de la classification.
- Les réseaux profonds hybrides sont la combinaison des deux types de réseaux mentionnés ci-dessus, de sorte que les réseaux profonds non supervisés pourraient fournir une excellente initialisation sur la base de laquelle la discrimination pourrait être examinée. [14]

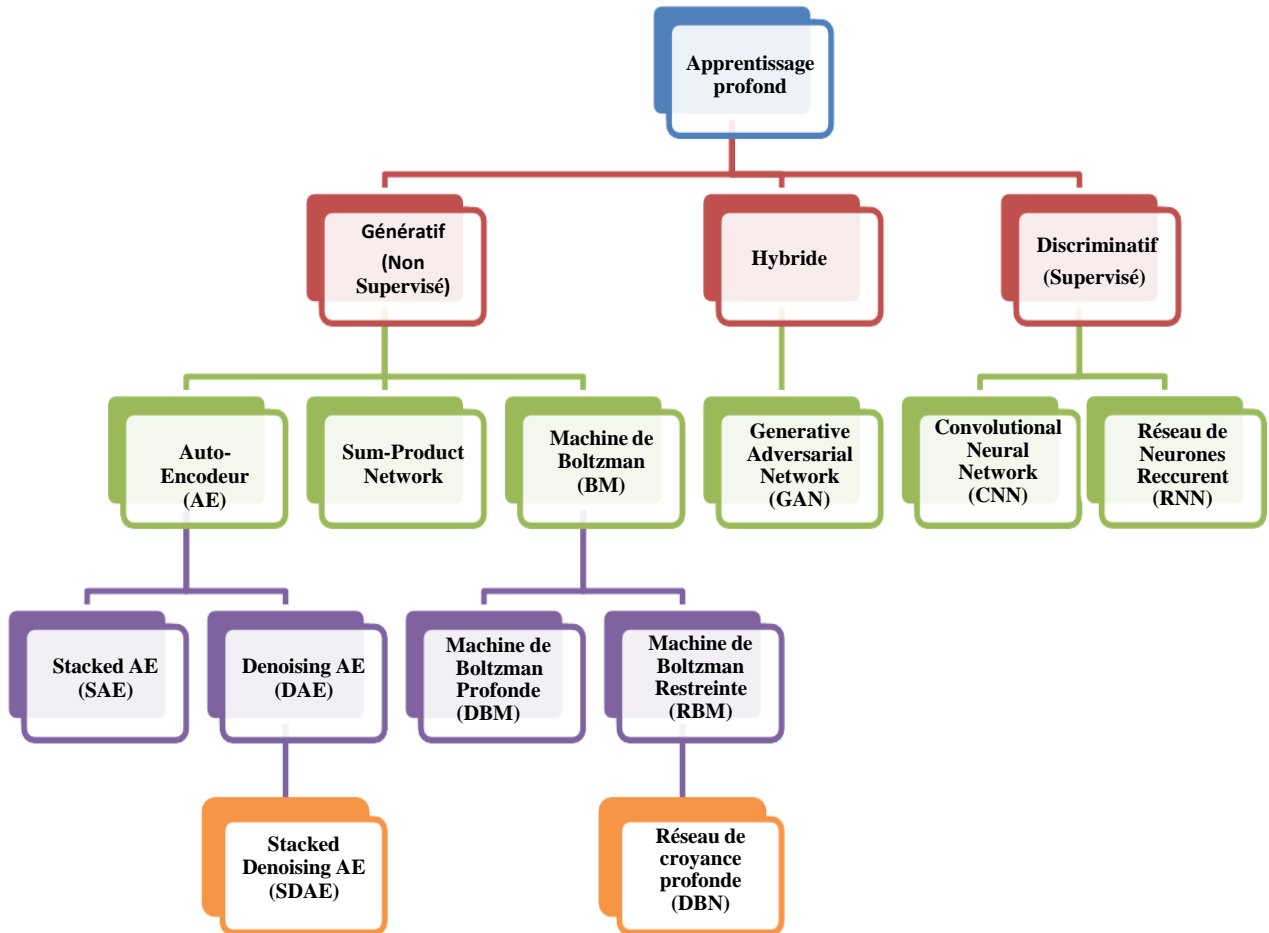


Figure 2.7 - Classification des méthodes d'apprentissage profond. [14]

## 2.10 Les différents types de modèles

Il existe un grand nombre de variantes d'architectures profondes. La plupart d'entre elles sont dérivées de certaines architectures parentales originales. Il n'est pas toujours possible de comparer les performances de toutes les architectures, car elles ne sont pas toutes évaluées sur les mêmes ensembles de données. Le Deep Learning est un domaine à croissance rapide, et de nouvelles architectures, variantes ou algorithmes. [12]

### 2.10.1 Réseau de neurones récurrents (RNN)

Les humains ne commencent pas leurs pensées à zéro à chaque seconde. Lorsqu'on lit un livre, on comprend chaque mot en fonction de la compréhension des mots précédents. On n'oublie pas tout et recommençons à réfléchir à nouveau. Nos pensées ont une persistance. Les réseaux de neurones traditionnels ne peuvent pas le faire, et cela est un inconvénient majeur. Par exemple, imaginons qu'on souhaite classer quel genre d'événement se produit à



chaque étape du film. On ne sait pas très bien comment un réseau de neurones traditionnels pourrait utiliser son raisonnement sur les événements précédents dans le film pour en informer les derniers.

RNN (les réseaux de neurones récurrents) traitent ce problème. Ce sont des réseaux avec des boucles, permettant aux informations de persister. [12]

L'idée derrière les RNN est d'utiliser des informations séquentielles. Dans un réseau neuronal traditionnel, nous supposons que toutes les entrées (et les sorties) sont indépendantes les unes des autres. Mais pour de nombreuses tâches, c'est une très mauvaise idée. Si on veut prédire le prochain mot dans une phrase, il faut connaître les mots qui sont venus avant. Les RNN sont appelés récurrents car ils exécutent la même tâche pour chaque élément d'une séquence, la sortie étant dépendante des calculs précédents. Une autre façon de penser les RNN est qu'ils ont une « mémoire » qui capture l'information sur ce qui a été calculé jusqu'ici. En théorie, les RNN peuvent utiliser des informations dans des séquences arbitrairement longues, mais dans la pratique, on les limite à regarder seulement quelques étapes en arrière. [12]

### 2.10.2 Perceptrons multicouches

Des réseaux neuronaux organisés en plusieurs couches (au moins une couche cachée) au sein desquelles une information circule de la couche d'entrée vers la couche de sortie uniquement ; il s'agit donc d'un réseau à propagation directe (feed-forward) avec propagation anticipée, couches entièrement connectées. Chaque couche est constituée d'un nombre variable de neurones, les neurones de la dernière couche (dite : de sortie) étant les sorties du système global. [14]

Le concept de base du perceptron singulier a été introduit par Rosenblatt en 1958. Le perceptron calcule une sortie unique à partir de multiples entrées à valeurs réelles en formant une combinaison linéaire en fonction de ses poids d'entrée, puis en plaçant éventuellement la sortie via une fonction d'activation non linéaire. Mathématiquement cela peut être écrit comme

$$y = \varphi(\sum_{i=1}^n w_i x_i + b) = \varphi(W^T X + b) \quad (2.2)$$

Avec

- $W$  désigne le vecteur des poids.
- $X$  est le vecteur des entrées.

- $B$  le biais.
- $\varphi$  représente la fonction d'activation. [14]

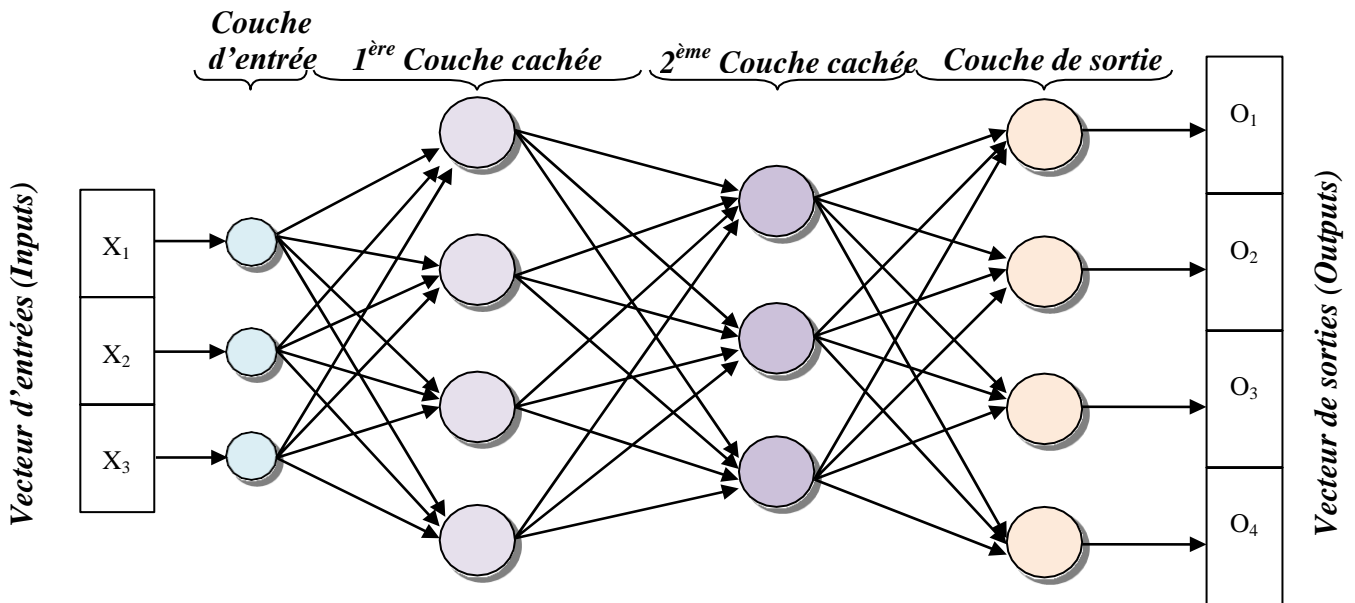


Figure 2.8 - Perceptron multicouches. [14]

Les réseaux MLP sont généralement utilisés dans les problèmes d'apprentissage supervisé. Cela signifie qu'il existe un ensemble d'apprentissage entrée/sortie et que le réseau doit apprendre à modéliser la dépendance entre elles. La formation ici signifie l'adaptation de tous les poids et biais à leurs valeurs optimales. [14]

### 2.10.3 Modèle génératif (deep generative model)

Alors qu'un modèle discriminatif (ex : CNN, RNN, MLP) essaye de prédire  $p(y/x)$  avec  $y$  étant le label et  $x$  l'entrée, un modèle génératif décrit comment les données sont générées, il apprend  $p(x, y)$  et fait des prédictions en utilisant la loi de Bayes pour calculer  $p(y/x)$ . Si le but est juste la classification, alors il faut utiliser un modèle discriminatif, cependant les modèles génératifs sont capables de bien plus que la simple classification comme par exemple générer de nouvelles observations. [12]

Voici quelques exemples de modèle génératif :

- Boltzmann Machines.
- Restricted Boltzmann Machines.
- Deep Belief Networks.
- Deep Boltzmann Machines.

- Generative Adversarial Networks.
- Generative Stochastic Networks.
- Adversarial autoencoders. [12]

#### **2.10.4 Réseaux de neurones convolutifs (CNN)**

Dans les algorithmes traditionnels de machine learning, la notion de features (caractéristiques) en vision sont utilisées pour faire de la classification d'images. Ces méthodes consistent à extraire les features de chaque image du jeu de données manuellement par un expert, puis à entraîner un classifieur sur ces features. Ces techniques d'apprentissage supervisé peuvent fournir de très bons résultats, et leur performance dépend fortement de la qualité des features préalablement trouvées. Il existe plusieurs méthodes d'extraction et de description de features (tel SIFT). [16]

Mais en 2012, une révolution se produit : lors de la compétition annuelle de vision par ordinateur ILSVRC, un nouvel algorithme de Deep Learning explose les records! Il s'agit d'un réseau de neurones convolutif CNN, [16] pour Convolutional Neural Network.

Les réseaux de neurones convolutifs ont une méthodologie similaire à celle des méthodes traditionnelles d'apprentissage supervisé : ils reçoivent des images en entrée, détectent les features automatiquement de chacune d'entre elles, puis entraînent un classifieur dessus. Donc les CNN réalisent eux-mêmes tout le boulot fastidieux d'extraction et description de features. Lors de la phase d'entraînement, l'erreur de classification est minimisée afin d'optimiser les paramètres du classifieur et les features! De plus, l'architecture spécifique du réseau permet d'extraire des features de différentes complexités, des plus simples au plus sophistiquées. L'extraction et la hiérarchisation automatiques des features, qui s'adaptent au problème donné constituent une des forces des réseaux de neurones convolutifs.

Aujourd'hui, les réseaux de neurones convolutifs CNN, aussi appelés ConvNet sont toujours les modèles les plus performants pour la classification d'images. [16]

##### **2.10.4.1 Définition de réseau de neurones convolutif**

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

1- Le premier bloc fait la particularité de ce type de réseaux de neurones, puisqu'il fonctionne comme un extracteur de features. Pour cela, en appliquant des opérations de filtrage par convolution. La première couche filtre l'image avec plusieurs noyaux de

convolution, et renvoie des "feature maps", qui sont ensuite normalisées (avec une fonction d'activation) et/ou redimensionnées. Ce procédé peut être réitéré plusieurs fois : on filtre les feature maps obtenues avec de nouveaux noyaux, ce qui nous donne de nouvelles feature maps à normaliser et redimensionner, et qu'on peut filtrer à nouveau, et ainsi de suite. Finalement, les valeurs des dernières feature maps sont concaténées dans un vecteur. Ce vecteur définit la sortie du premier bloc, et l'entrée du second.

2- Le second bloc : Les valeurs du vecteur en entrée sont transformées (avec plusieurs combinaisons linéaires et fonctions d'activation) pour renvoyer un nouveau vecteur en sortie. Ce dernier vecteur contient autant d'éléments qu'il y a de classes : l'élément  $i$  représente la probabilité que l'image appartienne à la classe  $i$ .

Comme pour les réseaux de neurones ordinaires, les paramètres des couches sont déterminés par rétro propagation du gradient : l'entropie croisée est minimisée lors de la phase d'entraînement. Mais dans le cas des CNN, ces paramètres désignent en particulier les features des images. [16]

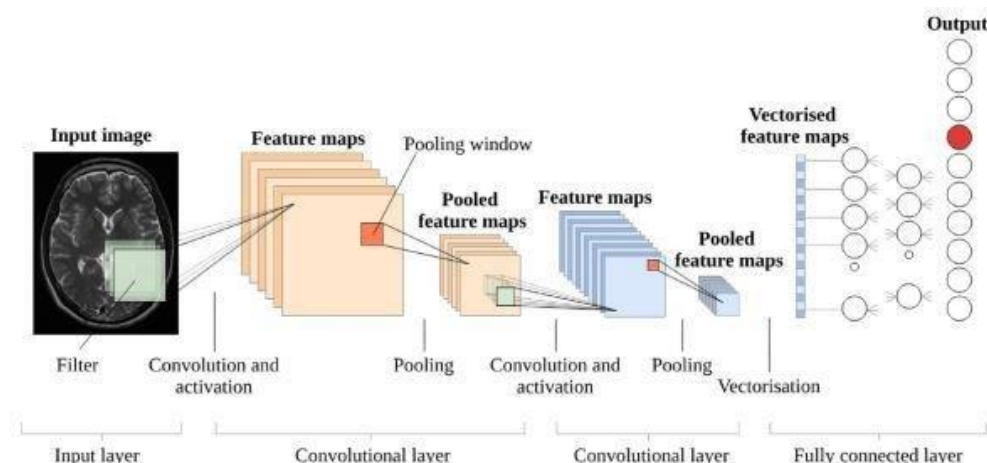


Figure 2.9 - Structure d'un réseau de neurones convolutifs. [34]

#### 2.10.4.2 CNN vs ANN


Dans un réseau neuronal artificiel traditionnel Rosenblatt (1962), Rumelhart *et al.* (1986) les neurones sont entièrement connectés entre différentes couches. Les neurones situés entre la couche d'entrée et la couche de sortie construisent les couches cachées. Chaque couche cachée est composée d'un certain nombre de neurones, ou chaque neurone est entièrement connecté à tous les neurones de la couche précédente. Le problème avec le réseau neuronal entièrement connecté est que son architecture de réseau densément connectée ne s'adapte pas bien aux grandes images. Pour les images de grande taille, l'approche la plus privilégiée consiste à utiliser un réseau neuronal convolutif. Les CNNs sont conçus pour traiter des

données qui ont une topologie de type grille connue. Ils ont trois caractéristiques clés : champ récepteur local, partage de poids et sous-échantillonnage (Pooling). [15]

- **Champ récepteur local** : Dans un réseau neuronal traditionnel, chaque neurone cachée est connecte à chaque neurone de la couche précédente. Les réseaux de neurones convolutifs cependant, ont une architecture de champ récepteur local, c'est-à-dire que chaque neurone cachée ne peut se connecter qu'à une petite région de l'entrée appelée champ récepteur local. Pour cela le filtre (poids) est plus petit que l'entrée. Avec le champ récepteur local, les neurones peuvent extraire des caractéristiques visuelles élémentaires comme les bords, les coins ... etc.

- **Partage de poids** : Le partage de poids fait référence à l'utilisation du même filtre pour tous les champs récepteurs d'une couche. Dans un CNN, puisque les filtres sont plus petits que l'entrée chaque filtre est appliqué à chaque position de l'entrée.

- **Sous-échantillonnage (Pooling)** : Le sous-échantillonnage réduit la taille spatiale des cartes de caractéristiques, réduisant ainsi les paramètres du réseau. Il existe peu de techniques de sous-échantillonnage disponibles, et les techniques de sous-échantillonnage les plus courantes sont Max-Pooling et Average-Pooling. [15]



**Figure 2.10** - Couches d'un réseau de neurone Vs un réseau de neurone à convolutions. [18]

### 2.10.4.3 Les différentes couches des réseaux de neurones convolutifs

Il existe un grand nombre de variables d'architectures profondes. La plupart d'entre eux sont des combinaisons de certaines architectures simples afin de développer des architectures plus complexes. Une architecture CNN est formée par un empilement de couches de traitement indépendantes. Dans la partie qui suit nous allons citer les couches les plus utilisées pour former un CNN :

### 2.10.4.3.1 La Couche de convolution CONV

La couche de convolution est la composante clé des réseaux de neurones convolutifs, et constitue toujours au moins leur première couche, son but est de repérer la présence d'un ensemble de caractéristiques (features) dans les images reçues en entrée. Pour cela, on réalise un filtrage par convolution : le principe est de faire "glisser" une fenêtre représentant la feature sur l'image, et de calculer le produit de convolution entre la feature et chaque portion de l'image balayée. Une feature est alors vue comme un filtre : les deux termes sont équivalents dans ce contexte. La couche de convolution reçoit donc en entrée plusieurs images, et calcule la convolution de chacune d'entre elles avec chaque filtre. Les filtres correspondent exactement aux features que l'on souhaite retrouver dans les images.

On obtient pour chaque paire (image, filtre) une carte d'activation, ou feature map, qui nous indique où se situent les features dans l'image : plus la valeur est élevée, plus l'endroit correspondant dans l'image ressemble à la feature. [35]

Trois hyper paramètres permettent de dimensionner le volume de la couche de convolution (Aussi appelé volume de sortie) : la profondeur, le pas et la marge.

1. Profondeur de la couche : nombre de noyaux de convolution (ou nombre de neurones associés à un même champ récepteur).
2. Le pas contrôle le chevauchement des champs récepteurs. Plus le pas est petit, plus les champs récepteurs se chevauchent et plus le volume de sortie sera grand.
3. La marge (à 0) ou 'zéro padding' : parfois, il est commode de mettre des zéros à la frontière du volume d'entrée. La taille de ce 'zéro-padding' est le troisième hyper paramètre. Cette marge permet de contrôler la dimension spatiale du volume de sortie. En particulier, il est parfois souhaitable de conserver la même surface que celle du volume d'entrée [36].

Prenons la Figure 2.11 ci-dessous à gauche comme exemple d'image et la Figure 2.12 à droite comme exemple de filtre. [16]

M

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

**Figure 2.11** - Exemple simpliste des valeurs d'une des pixels d'une image 5x5. [16]

F

1	0	1
0	1	0
1	0	1

**Figure 2.12** - Exemple de valeurs Matrice utilisée comme filtre. [16]

Dans le cas de la Figure 2.11, les valeurs sont binaires. Dans un cas réel, les valeurs devraient varier entre 0 et 255. Dans la Figure 2.12, les valeurs sont représentées par des 1 et 0. Dans un cas réel, ces valeurs sont continues et peuvent être positives ou négatives.

Appliquer le filtre sur l'image : dans la matrice image M, nous pouvons voir que chaque valeur des pixels de l'image tuile (les cases orange) est multipliée par chaque valeur correspondante du filtre (1x1, 1x0, 1x1 ....). Puis additionner tous ces valeurs pour obtenir une seule valeur '4' qui fera partie d'une nouvelle image convoluée. [16]

Le filtre doit se déplacer d'une case à chaque itération jusqu'à ce que la première ligne soit finie. Lorsque nous avons fini la première ligne, le filtre « descend » d'une case et la même procédure se répète pour chaque ligne et colonne. Voir l'animation suivante :

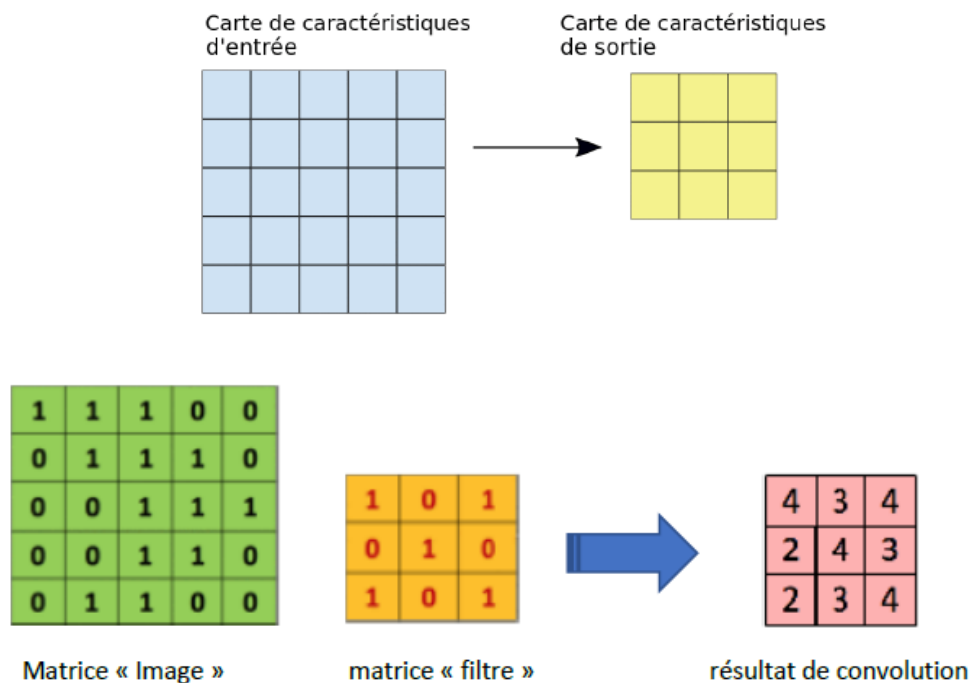


Figure 2.13 – Opération de convolution. [16]

Noté qu'une convolution 3x3 de profondeur 1 effectuée sur une carte de caractéristiques d'entrée 5x5, également de profondeur 1. Comme il y a neuf emplacements 3x3 possibles pour extraire les tuiles de la carte de caractéristiques 5x5, cette convolution génère une carte de caractéristiques de sortie 3x3.

Un réseau de neurones à convolution contient de multiples filtres et ces filtres sont appliqués sur l'image d'origine. Après la première étape nous avons donc autant de nouvelles images que de filtres. La phase de convolution peut aussi être vue comme des couches de

neurones cachées où chaque neurone n'est connecté qu'à quelques neurones de la couche suivante. [16]

#### ▪ Effets d'application de filtres

Pour expliquer comment un filtre peut trouver des parties intéressantes dans les images. Prenons le Filtre précédant. Les valeurs qui sont à 1 forment un «X». Pendant la phase de convolution, lorsque ce filtre sera appliqué à une forme qui correspond exactement à un «X» alors la valeur obtenue sera plus élevée. Moins la forme de l'image correspond à la forme du filtre, plus la valeur obtenue sera basse. Nous pouvons donc réduire la taille de l'image et en faire ressortir les éléments intéressants. [16]

#### ▪ Les fonctions d'activations


La sortie de chaque couche convolutionnelle est envoyée à une couche de fonction d'activation. La couche de fonction d'activation se compose d'une fonction d'activation qui prend la carte de caractéristiques produite par la couche de convolution et génère la carte d'activation comme sortie. La fonction d'activation est utilisée pour transformer le niveau d'activation d'un neurone en un signal de sortie. Il spécifie la sortie d'un neurone vers une entrée donnée. Une fonction d'activation a généralement un effet d'écrasement qui prend une entrée (un nombre) effectue une opération mathématique sur elle et génère le niveau d'activation d'un neurone dans une plage donnée, par exemple, 0 à 1 ou -1 à 1. En général, 3 propriétés sont attendues de la fonction d'activation : [15]

- **Non linéarité** : c'est la propriété cruciale de la fonction d'activation. Grâce à cette propriété le réseau de neurones peut être utilisé pour résoudre des problèmes non linéaires.

- **Différentiable** - ce qui signifie que nous avons une dérivée continue du premier ordre. C'est une propriété souhaitable pour activer des méthodes d'optimisation basées sur un gradient comme la rétro-propagation Rumelhart et al. (1986).

- **Monotone** Cette caractéristique aide le réseau de neurones à converger plus facilement vers un modèle plus précis. De nombreuses fonctions d'activation sont utilisées comme l'indique la figure 2.14. [15]





**Figure 2.14** - Quelques fonctions d'activation. [15]

En pratique, on utilise le ReLU comme activation pour les couches cachées car cette dernière accélère le processus d'entraînement. Le calcul du gradient est très simple (0 ou 1 selon le signe de  $x$ ). De plus, le calcul d'un ReLU est facile : tous les éléments négatifs sont mis à 0, donc pas d'exponentiels, pas d'opérations de multiplication ou de division. Pour la couche de sortie, on utilise Sigmoid pour un problème de classification binaire. Par contre pour la classification multi classe, on définit la fonction Softmax qui est représentée mathématiquement par : [15]

$$\sigma(x_i) = \frac{e^{x_i}}{\sum_j e^{x_j}} \quad (2.3)$$

#### 2.10.4.3.2 Couche de correction (ReLU)

Il est possible d'améliorer l'efficacité du traitement en intercalant entre les couches de traitement une couche qui va opérer une fonction mathématique (fonction d'activation) sur les signaux de sortie. Cette couche est la fonction ReLU (Rectified Linear Units) :

$$f(x) = \max(0, x) \quad (2.4)$$

Elle remplace donc toutes les valeurs négatives reçues en entrées par des zéros.

Cette fonction, appelée aussi « fonction d'activation non saturante », elle augmente les propriétés non linéaires de la fonction de décision et de l'ensemble du réseau sans affecter les champs récepteurs de la couche de convolution. Souvent, la correction Relu est préférable, car il en résulte la formation de réseau neuronal plusieurs fois plus rapide, sans faire une différence significative à la généralisation de précision. [36]

### 2.10.4.3.3 La couche pooling (POOL)

Un autre concept important des CNN est le pooling, ce qui est une forme de sous échantillonnage de l'image. L'image d'entrée est découpée en une série de rectangles de  $n$  pixels de côté ne se chevauchant pas (pooling). Le pooling réduit la taille spatiale d'une image intermédiaire, réduisant ainsi la quantité de paramètres et de calcul dans le réseau. Il est donc fréquent d'insérer périodiquement une couche de pooling entre deux couches convolutive successives d'une architecture CNN pour contrôler l'overfitting (sur-apprentissage). [36]

L'opération de pooling créait aussi une forme d'invariance par translation. La couche de pooling fonctionne indépendamment sur chaque tranche de profondeur de l'entrée et la redimensionne uniquement au niveau de la surface. La forme la plus courante est une couche de mise en commun avec des fenêtres de taille  $2 \times 2$  (largeur/hauteur) et comme valeur de sortie la valeur maximale en entrée. On parle dans ce cas de 'Max-Pool  $2 \times 2$ '. [36]

Il est possible d'utiliser d'autres fonctions de pooling que le maximum. On peut utiliser 'un average pooling' (la sortie est la moyenne des valeurs de l'entrée), Dans les faits, même si initialement l'average pooling était souvent utilisé il s'est avéré que le max-pooling était plus efficace car celui-ci augmente plus significativement l'importance des activations fortes. En d'autres circonstances on pourra utiliser un pooling stochastique.

Le pooling permet de gros gains en puissance de calcul. Cependant, en raison de la réduction agressive de la taille de la représentation (et donc de la perte d'information associée), la tendance actuelle est d'utiliser de petits filtres (de taille  $2 \times 2$  ou  $3 \times 3$ ). Il est aussi possible d'éviter la couche de pooling mais cela implique un risque sur-apprentissage plus important. [36]

#### a. Max Pooling




Figure 2.15 - Exemple du Max Pooling. [17]

#### b. Moyenne Pooling

Si on avait plutôt choisi l'opération moyenne pooling pour le réseau, la sortie associée à l'opération pooling aurait été donnée par : [17]




Figure 2.16 - Exemple du Moyenne pooling. [17]

**c. Global pooling**



Figure 2.17 - Exemple du global pooling. [17]

**2.10.4.3.4 Couche entièrement connectée (FC)**

La couche entièrement connectée (fully connected FC) constitue généralement la dernière couche d'un réseau de neurones convolutif. Ce type de couche reçoit un vecteur en entrée et produit un nouveau vecteur en sortie. Pour cela elle applique une combinaison linéaire puis éventuellement une fonction d'activation aux valeurs reçues en entrée. Elle permet de classifier l'image en entrée du réseau : elle renvoie un vecteur de taille NN, où NN est le nombre de classes dans le problème de classification d'images. Chaque élément du vecteur indique la probabilité pour l'image en entrée d'appartenir à une classe. Chaque valeur du tableau en entrée "vote" en faveur d'une classe. Les votes n'ont pas tous la même importance la couche leur accorde des poids qui dépendent de l'élément du tableau et de la classe. [35]

Pour calculer les probabilités, la couche fully-connected multiplie donc chaque élément en entrée par un poids, fait la somme, puis applique une fonction d'activation (Soft max).

Ce traitement revient à multiplier le vecteur en entrée par la matrice contenant les poids. Le fait que chaque valeur en entrée soit connectée avec toutes les valeurs en sortie explique le terme fully-connected. [35]

**2.10.4.3.5 Couche de dé-convolution**

La couche déconvolutionnelle inverse le fonctionnement d'une couche convolutionnelle standard afin de récupérer l'entrée d'origine. La couche convolutionnelle transposée est similaire à la couche déconvolutionnelle en ce sens que la dimension spatiale générée par les

deux est la même. La convolution transposée n'inverse pas la convolution standard par des valeurs, mais uniquement par des dimensions. Cette couche est utilisée dans le cas de la segmentation des images. [36]

#### **2.10.4.4.6 Couche de perte (LOSS)**

La couche de perte spécifie comment l'entraînement du réseau pénalise l'écart entre le signal prévu et le signal réel. Elle est normalement la dernière couche dans le réseau. Diverses fonctions de perte adaptées à différentes tâches peuvent y être utilisées. La perte ' Softmax ' est utilisée pour prédire une seule classe parmi K classes mutuellement exclusives. La perte euclidienne est utilisée pour régresser vers des valeurs réelles. [36]

#### **2.10.4.4.7 Couche de normalisation (BN)**

La normalisation est une technique d'entraînement de réseaux de neurones très profonds qui standardise les entrées d'une couche pour chaque mini-lot. Cela a pour effet de stabiliser le processus d'apprentissage et de réduire considérablement le nombre d'époques de formation nécessaires pour former des réseaux profonds. [36]

#### **2.10.4.4.8 Couche de régularisation (Dropout)**

Entre chaque couche dense, il est commun d'utiliser du dropout. C'est une technique de régularisation (pour combattre l'overfitting) dont le principe est de désactiver aléatoirement à chaque itération un certain pourcentage des neurones d'une couche. Cela évite ainsi la sur spécialisation d'un neurone (et donc l'apprentissage par cœur). [36]

#### **2.10.4.5 Quelques réseaux convolutifs célèbres**

- **LeNet** : Les premières applications réussies des réseaux convolutifs ont été développées par Yann LeCun dans les années 1990. Parmi ceux-ci, le plus connu est l'architecture LeNet utilisée pour lire les codes postaux, les chiffres, etc. [12]
- **AlexNet**: Le premier travail qui a popularisé les réseaux convolutifs dans la vision par ordinateur était AlexNet, développé par Alex Krizhevsky, Ilya Sutskever et Geoff Hinton. AlexNet a été soumis au défi ImageNet ILSVRC en 2012 et a nettement surpassé ses concurrents. Le réseau avait une architecture très similaire à LeNet, mais était plus profond plus grand et comportait des couches convolutives empilées les unes sur les autres (au paravant, il était commun de ne disposer que d'une seule couche convolutifs toujours immédiatement suivie d'une couche de pooling).

- **ZFnet**: Le vainqueur de ILSVRC challenge 2013 était un réseau convolutif de Matthew Zeiler et Rob Fergus. Il est devenu ZFNet (abréviation de Zeiler et Fergus Net). C'était une amélioration de AlexNet en ajustant les hyper-paramètres de l'architecture, en particulier en élargissant la taille des couches convolutifs et en réduisant la taille du noyau sur la première couche. [12]
- **GoogLeNet**: Le vainqueur de ILSVRC challenge 2014 était un réseau convolutif de Szegedy et al. De Google. Sa principale contribution a été le développement d'un module inception qui a considérablement réduit le nombre de paramètres dans le réseau (4M, par rapport à AlexNet avec 60M). En outre, ce module utilise le global AVG pooling au lieu du PMC à la fin du réseaux, ce qui élimine une grande quantité de paramètres. Il existe également plusieurs versions de GoogLeNet, parmi elles, Inception-v4.
- **ResNet**: Residual network développé par Kaiming He et al. A été le vainqueur de ILSVRC 2015. Il présente des sauts de connexion et une forte utilisation de la batch normalisation. Il utilise aussi le global AVG pooling au lieu du PMC à la fin. [12]
- **Vgg** : Ce réseau se caractérise par sa simplicité, n'utilisant que  $3 \times 3$  couches convolutives empilées les unes sur les autres en profondeur croissante. La réduction de la taille du volume est gérée par la mise en commun maximale. Deux couches entièrement connectées, chacune avec 4096 nœuds, sont ensuite suivies d'un classificateur softmax. Le Dropout fonctionne en déconnectant de manière aléatoire les nœuds de la couche actuelle à la couche suivante. Ce processus de déconnexions aléatoires pendant les lots d'apprentissage aide à introduire naturellement la redondance dans le modèle [17].

#### 2.10.4.6 Transfert Learning

L'apprentissage par transfert est de plus en plus évoqué en Data Science faisant référence à un ensemble de méthodes qui permettent le transfert de connaissances de la résolution d'un problème donné à la résolution d'un autre problème. L'apprentissage par transfert a été un grand succès avec l'essor du Deep Learning. En effet, très souvent les modèles utilisés dans ce domaine nécessitent beaucoup de temps de calcul et des ressources considérables. Cependant, en utilisant des modèles pré-entraînés comme point de départ, l'apprentissage par transfert permet de développer des modèles hautes performances rapidement et efficacement pour résoudre des problèmes complexes de vision par ordinateur ou de traitement du langage naturel [37].

## **2.11 Conclusion**

Dans ce chapitre, nous avons vu premièrement quelque généralités sur les réseaux de neurones artificiels, ensuite nous avons vu qu'est-ce que le Deep Learning, et les réseaux de neurones convolutifs CNN, les couches principaux de ces réseaux, et de quelques types de modèles utilisant des architectures d'apprentissage en profondeur.

Dans le chapitre suivant, nous avons proposé une conception pour notre système de détection des tumeurs cérébrales.

# *Chapitre 3*

## *Conception du Système*

### **Sommaire**

---

- 3.1 Introduction.**
  - 3.2 Principes de réseau de neurones à convolution.**
  - 3.3 Construction du modèle CNN.**
  - 3.4 Structure des données.**
  - 3.5 Augmentation des données.**
  - 3.6 Architecture de notre système.**
  - 3.7 Mise en œuvre de notre système.**
  - 3.8 La base de données.**
  - 3.9 Prétraitement des images IRM.**
    - 3.9.1 Redimensionnement d'image.**
    - 3.9.2 Recadrage d'image.**
    - 3.9.3 Augmentation de données.**
  - 3.10 Architecture du modèle CNN de notre système.**
  - 3.11 Procédure de détection d'une tumeur cérébrale en utilisant CNN.**
  - 3.12 Conclusion.**
-

### 3.1 Introduction

Les techniques d'apprentissage en profondeur se développent avec des architectures plus sophistiquées et complexes. Et avec la difficulté de former ces modèles avec les ensembles de données disponibles dans le domaine médical en raison de leur taille limitée, de leur variabilité. Il existe un fort besoin de concevoir des architectures plus simples mais puissantes capables de gérer avec succès le problème de la détection des tumeurs cérébrales. Pour atteindre cet objectif, nous présentons dans ce chapitre un modèle d'apprentissage profond basé sur CNN. Ce modèle extrait les caractéristiques depuis des images IRM et détecte la présence ou l'absence d'une tumeur cérébrale.

### 3.2 Principes de réseau de neurones à convolution

Les réseaux de neurones à convolution désignent une sous-catégorie de réseaux de neurones : ils présentent donc toutes les caractéristiques et les différentes méthodologies du réseau de neurones. Cependant, les CNN sont spécialement conçus pour traiter des images en entrée. L'architecture d'un réseau de neurones à convolution est formée par une succession de blocs de traitement pour extraire les caractéristiques discriminant la classe d'appartenance de l'image des autres. Un bloc de traitement se compose d'une à plusieurs :

- Couches de convolution (CONV) qui traitent les données d'un champ récepteur.
- Couches de correction (ReLU).
- Couches de pooling (POOL) qui permet de compresser l'information en réduisant la taille de l'image intermédiaire (souvent par sous échantillonnage).

Les blocs de traitement s'enchaînent jusqu'aux couches finales du réseau qui réalisent la classification de l'image et le calcul de l'erreur entre la prédiction et la valeur cible.

- Couche « entièrement connectée » (FC), qui est une couche de type perceptron.
- Couche de perte (LOSS). [31]

### 3.3 Construction du modèle CNN

Le choix des hyper-paramètres dans un apprentissage profond est une étape très importante pour optimiser l'algorithme et rendre robuste. Ces choix résident sur :

- Les nombres des couches.
- Les nombres des filtres.
- Les choix sur les tailles des filtres, comme, comment choisir entre les filtres de taille  $1 \times 1$  ou  $3 \times 3$  ou  $5 \times 5$  et bien d'autres.
- Quelle fonction d'activation à utiliser pour les différentes couches.



- Les nombres de couches connectées
- L'optimizer à utiliser et les hyper-paramètres des optimiseurs.
- Le taux d'apprentissage.

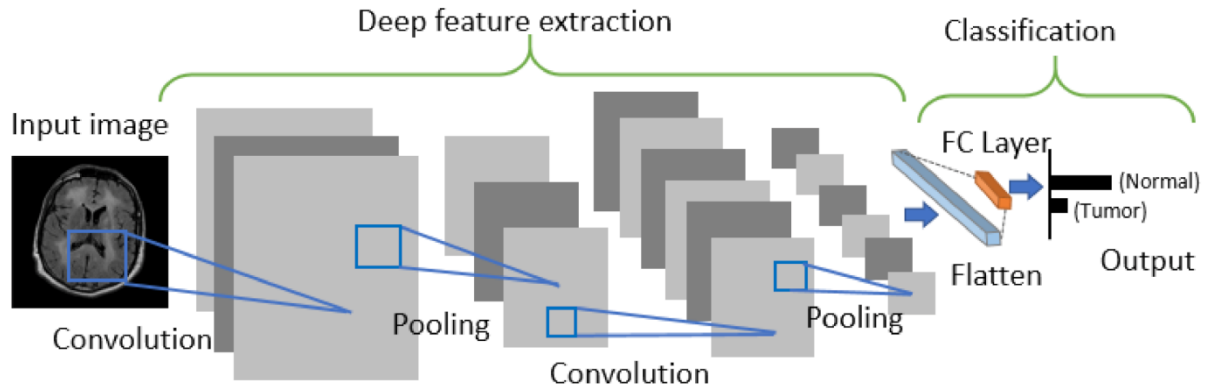


Figure 3.1 - Architecture de réseau de neurones convolutif. [32]

### 3.4 Structure des données

Les données sont classées en deux parties : une partie contenant les tumeurs et une partie sans une présence de tumeur. Les images ressemblent à :




Figure 3.2 - Image en présence d'une tumeur. [33]





Figure 3.3 - Image d'un cerveau normal. [33]

### 3.5 Augmentation des données

Une insuffisance de données risque le non apprentissage au niveau du modèle, car le modèle n'arrive même pas à apprendre des données. Cette insuffisance provoque aussi un surentrainement du réseau, car le modèle s'entraîne sur le peu de données d'entraînement et a une bonne précision au niveau de l'entraînement, mais n'arrive pas à reconnaître une nouvelle image qu'il n'a pas étudiée.

Une solution pour résoudre à cela est l'augmentation d'image. Les différentes techniques sont: Symétrie axiale, Rotation, Recadrage aléatoire, Changement de couleur, Addition de bruit, Zoom, Changement de contraste.

Ci-après une représentation d'une image après une augmentation : [31]



**Figure 3.4** - Une image augmentée. [31]

### 3.6 Architecture de notre système

Notre objectif dans ce travail est de détecter la tumeur cérébrale par les réseaux de neurones convolutifs à partir des images IRM de différentes coupes (axiale, sagittale, et coronale). La figure 3.6 présente l'architecture externe de notre système, avec ses différentes étapes :

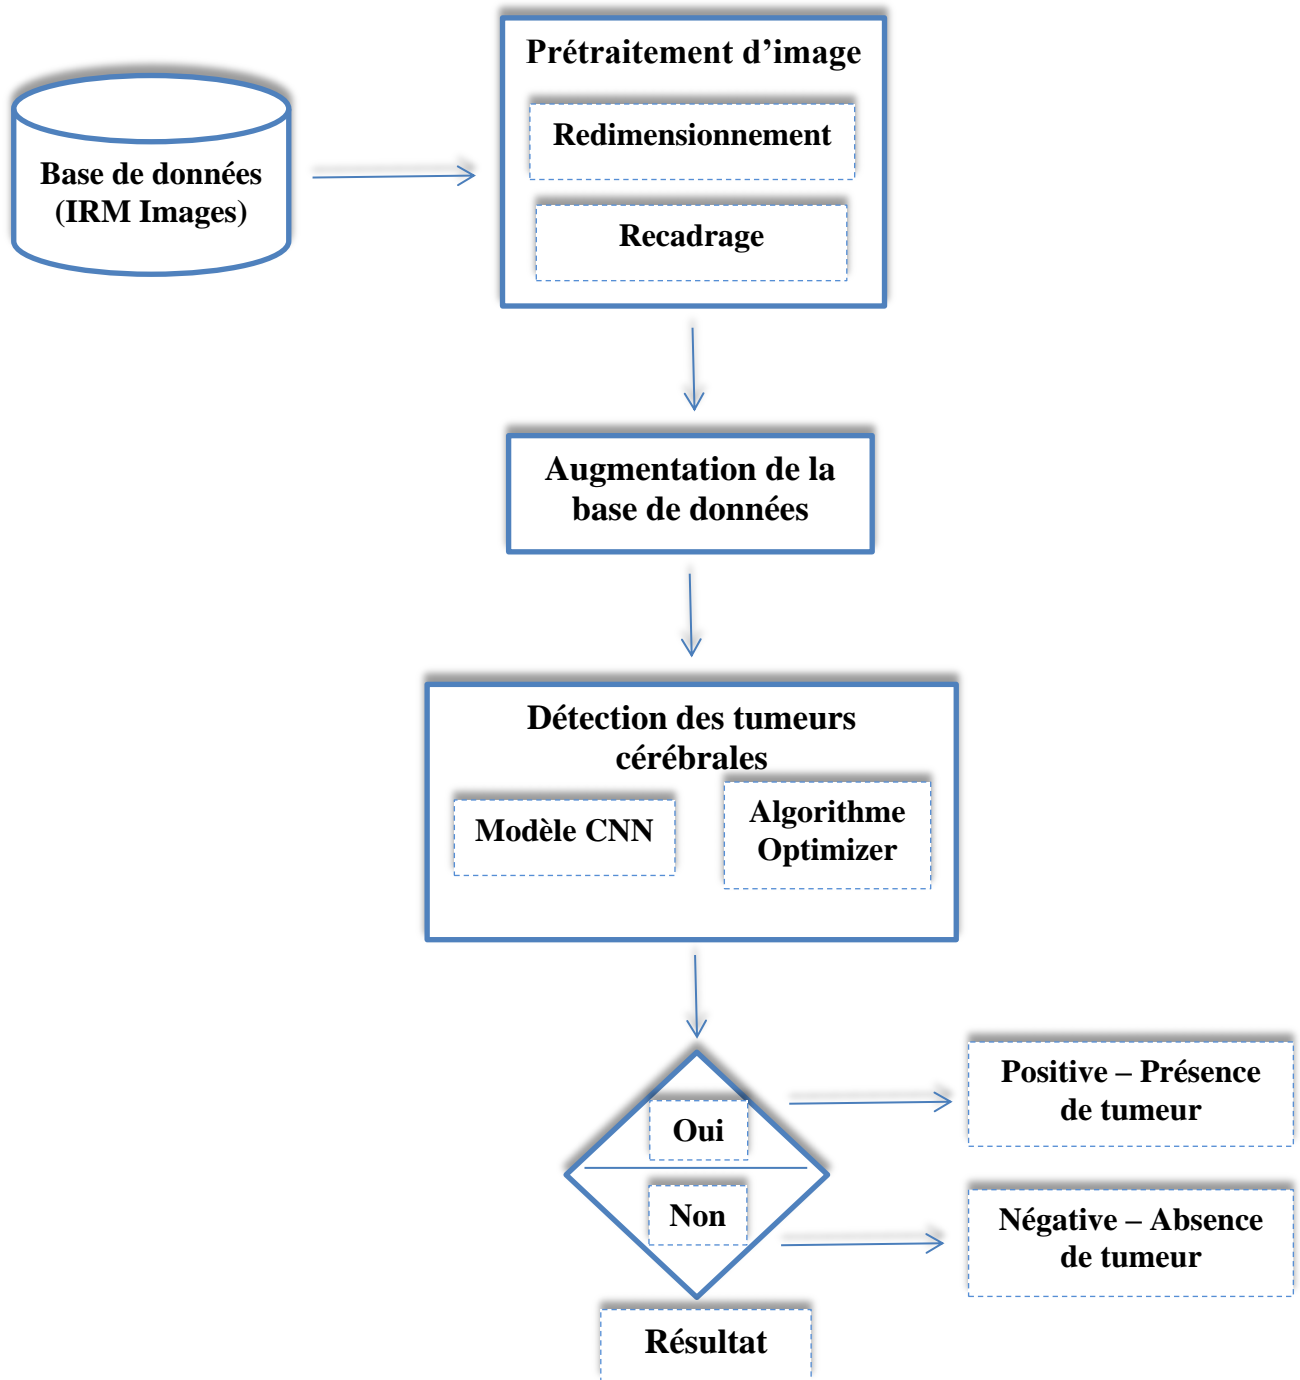
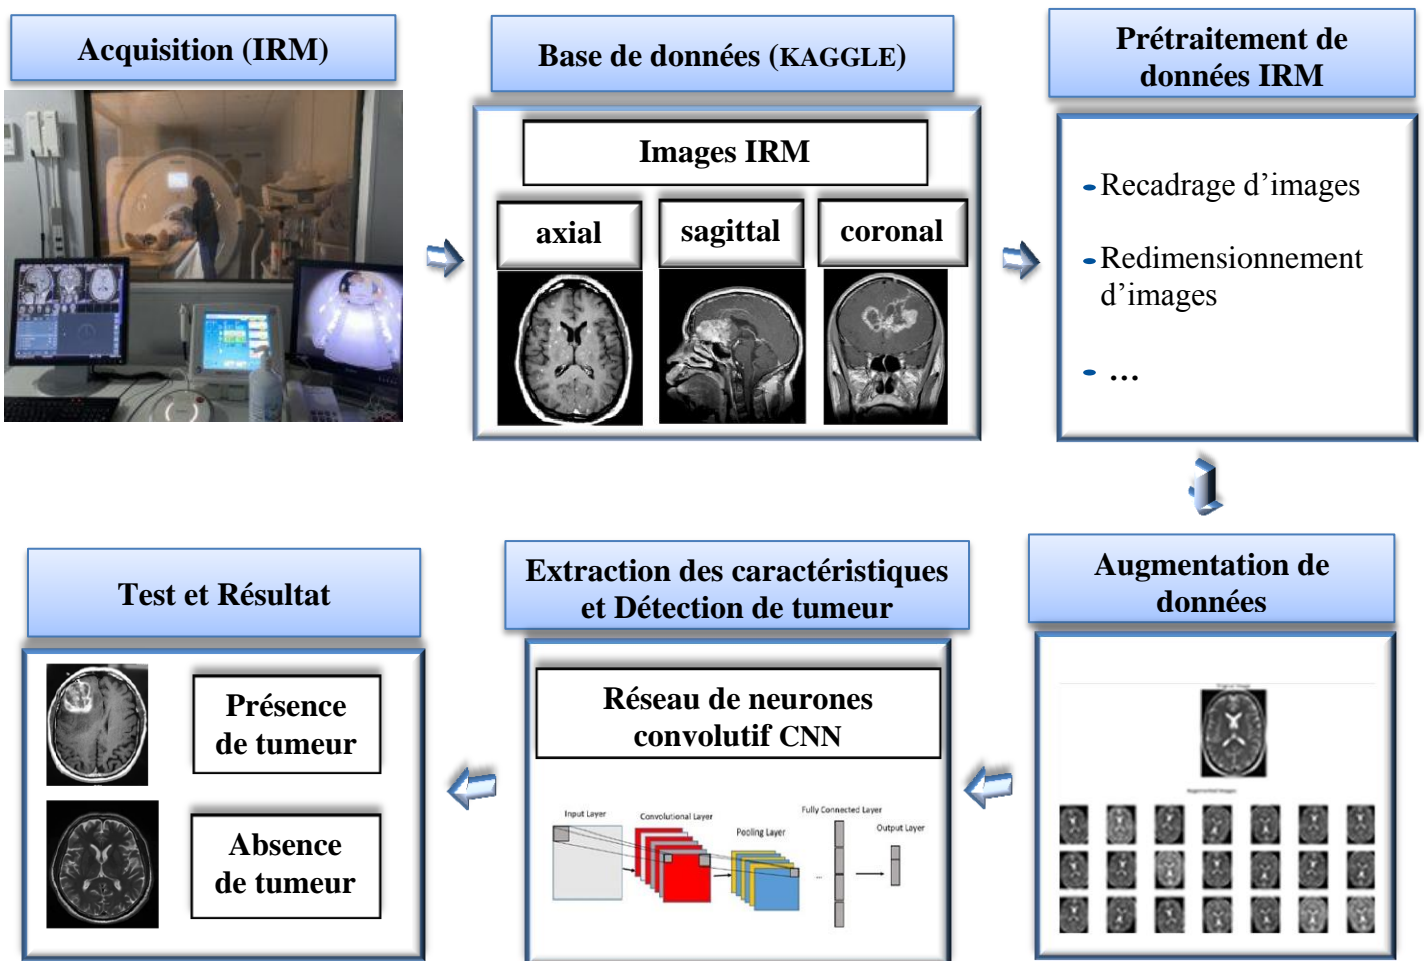


Figure 3.5 - Architecture de notre système.

### 3.7 Mise en œuvre de notre système

Le schéma de la figure 3.6, illustre la mise en œuvre de notre système :



**Figure 3.6** – Les différentes étapes de détection d’une tumeur cérébrale par réseau de neurones convolutif.

### 3.8 La base de données

L’ensemble de données IRM d’entraînement et de validation utilisée dans ce travail est un ensemble de données accessible au public, ont été téléchargées sur le site KAGGLE [33], qui devient étiqueté en quatre classes avec une tumeur (glioma\_tumor, meningioma\_tumor pituitary\_tumor) et sans tumeur (no\_tumor).

La base de données contient au total 3264 images d’IRM cérébrales de différentes formes et longueurs. Cet ensemble de données a en outre étiqueté en deux types avec tumeur et sans tumeur, 2475 images appartenait à la classe tumorale (glioma\_tumor meningioma\_tumor pituitary\_tumor) et 395 images IRM appartiennent à l’éléance normale (no\_tumor) pour l’entraînement et 289 images appartenait à la classe tumorale (glioma\_tumor

meningioma\_tumor pituitary\_tumor) et 105 images IRM appartiennent à l'élégance normale (no\_tumor) pour la validation. Le jeu de données a le format jpeg.

Après de retirer 50 images de la base de données pour le test de la détection de la tumeur cérébrale, nous avons mélangé toutes les images de la base de données et divisé la base de données en deux ensembles : des données d'entraînement et des données de validation en 80% et 20% d'une façon aléatoire.

## **3.9 Prétraitement des images IRM**

### **3.9.1 Redimensionnement d'image**

Les images de la base de données sont de tailles, de largeur et de hauteur différente, il est recommandé de les redimensionner à une hauteur et une largeur égale pour obtenir des résultats optimaux, il est également souhaitable de redimensionner les images de manière à ce qu'elles ne perdent pas leurs informations importantes ou ne dégradent pas leur qualité.

Dans ce travail, les images IRM sont redimensionnées en largeur, hauteur et canal ( $160 \times 160 \times 3$ ), la raison spécifique de choisir cette taille est que notre modèle proposé donne des résultats acceptable par rapport à d'autres tailles.

### **3.9.2 Recadrage d'image**

Il est nécessaire de recadrer les images pour ne conserver que les informations utiles et supprimer les zones indésirables. Pour recadrer les images, on utilise le calcul des points extrêmes et la recherche de leur contour.

### **3.9.3 Augmentation de données**

Le grand ensemble de données d'entraînement améliore les performances du modèle DL. L'augmentation des données est la technique permettant de créer un ensemble de données en modifiant l'ensemble de données d'origine, et également connu comme le processus de création de plusieurs copies de l'image originale avec différentes orientation.

### 3.10 Architecture du modèle CNN de notre système

L'entrée une image sous la forme d'une matrice de pixels.

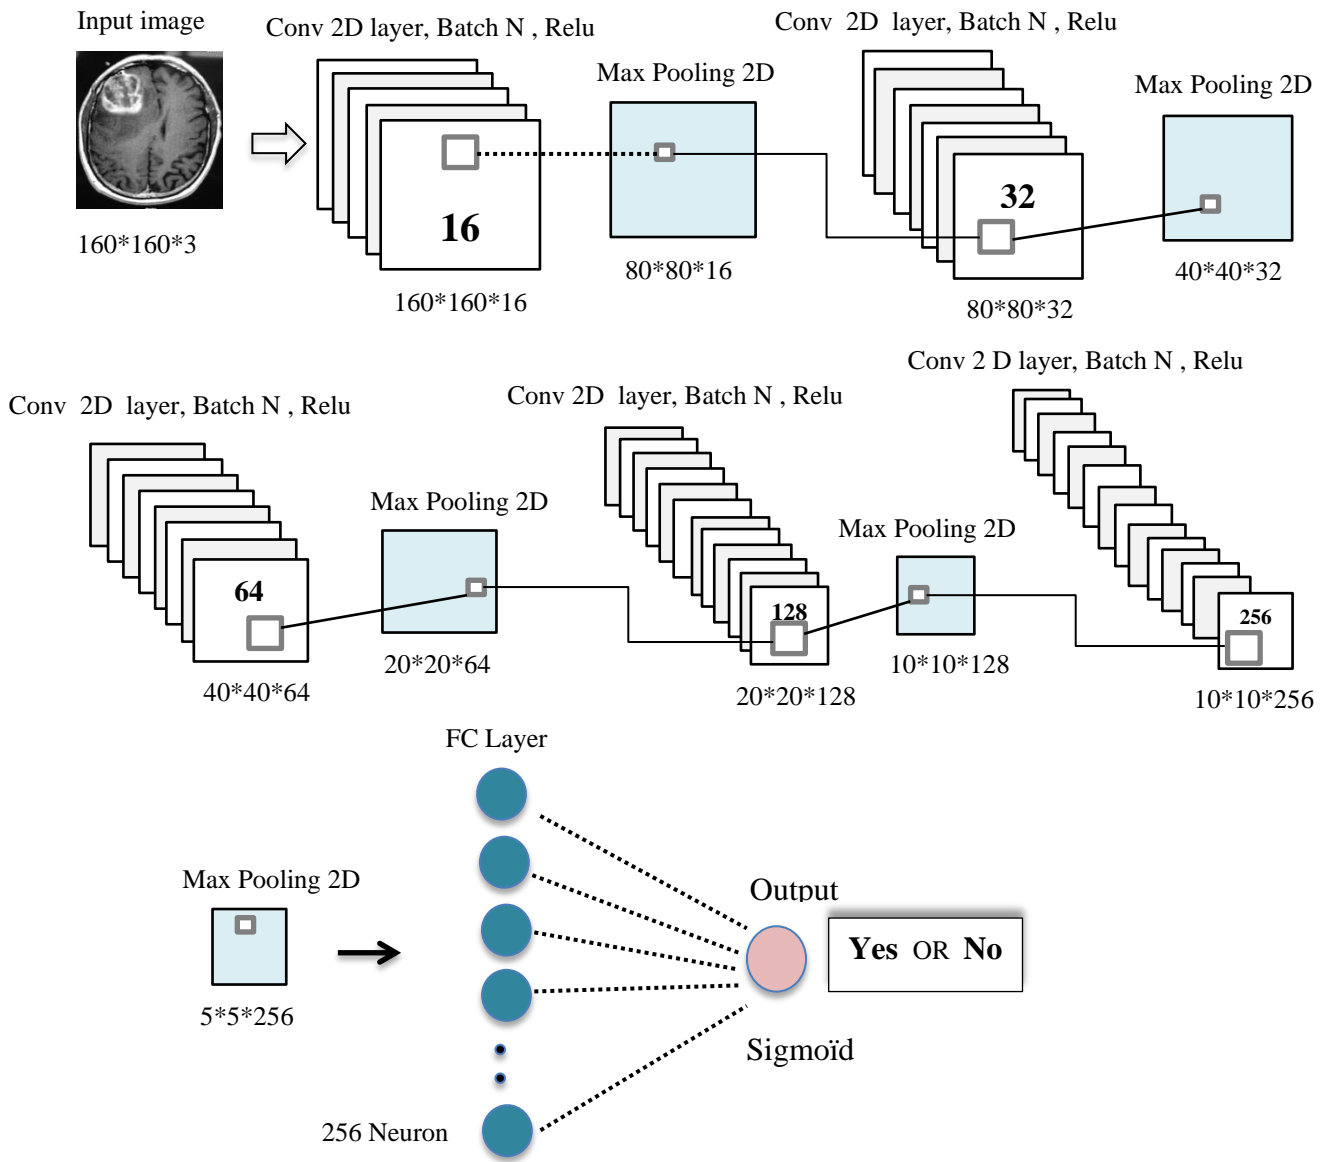


Figure 3.7 – Architecture du modèle CNN de notre système.

### 3.11 Procédure de détection d'une tumeur cérébrale en utilisant CNN

---

**Algorithme** Procédure de détection d' une tumeur cérébrale

**Exiger:** *model*: le modèle CNN pour la détection d' une tumeur cérébrale

**Exiger:** *img*: image IRM du cerveau à détecté

**Assurer:** *res: resultats* : le résultat de la détection d' une tumeur cérébrale

(**VRAI**: Tumeur détectée/ **FAUX**: Tumeur non détectée)

```
res ← model.detect(img);  
if res== 1 then  
    print(" Tumeur détectée");  
    return VRAI;  
else  
    print(" Il n'y a pas de tumeur" );  
    return FAUX;  
end if
```

---

### 3.12 Conclusion

Dans ce chapitre nous avons vu la conception externe de notre système, la structure de données utilisée dans notre travail, la mise en œuvre et les étapes de détection d'une tumeur cérébrale, nous avons parlé également de la construction de réseau de neurones convolutif, et nous avons proposé un modèle CNN pour notre système.

Dans le chapitre suivant nous présenterons l'implémentation de notre système.

# *Chapitre 4*

## *Implémentation et Résultats*

### **Sommaire**

---

#### **4.1 Introduction.**

#### **4.2 Ensembles de données d'entraînement, de validation et de test.**

#### **4.3 Environnement de développement de système.**

##### **4.3.1 Environnement matériel.**

##### **4.3.2 Environnement logiciel.**

#### **4.4 Implémentation et résultat.**

##### **4.4.1 Paramètres d'entraînement.**

##### **4.4.2 Prétraitement des données.**

##### **4.4.3 Architecture de réseau.**

##### **4.4.4 Résultat et discussion.**

##### **4.4.5 Ajout d'une couche Dropout a notre réseau.**

##### **4.4.6 Recadrage des images IRM et les résultats obtenus.**

##### **4.4.7 Augmentation de la base de données, Recadrage des images IRM et les résultats obtenus.**

#### **4.5 Le fonctionnement de l'application.**

##### **4.5.1 Prétraitement des données, création du modèle CNN, et apprentissage.**

##### **4.5.2 La courbe de perte (loss) et la courbe de précision (accuracy).**

##### **4.5.3 Partie de test.**

##### **4.5.4 Interface de l'application.**

#### **4.6. Travaux existants**

#### **4.7 Conclusion.**

---



## **4.1 Introduction**

Ce dernier chapitre est consacré à l'implémentation de système proposé dans le chapitre précédent, 'la détection des tumeurs cérébrales en utilisant le CNN', et à leur évaluation selon différents critères proposés, afin d'améliorer les performances du modèle que ce soit en temps ou en efficacité. La méthode proposée a été appliquée sur des images IRM.

Nous allons nous intéresser à la problématique de la détection de tumeur cérébrale qui est la tâche d'attribuer à une image 'IRM' d'entrée  $X$  un label  $y$  à partir d'un ensemble de deux classes (Oui : présence d'une tumeur et Non : absence d'une tumeur). C'est l'un des problèmes fondamentaux de la vision par ordinateur qui malgré sa simplicité, a une grande variété d'applications pratiques.

## **4.2 Ensembles de données d'entraînement, de validation et de test**

Afin de réaliser notre modèle CNN qui aide à la détection des tumeurs cérébrales, il fallait construire une base de données contenant des images IRM. Les hôpitaux et les centres d'imagerie médicale n'étaient pas utiles car ils classent la nature de notre base de données en tant que 'sensible' et parmi les informations confidentielles des patients. La solution était les plateformes 'Open Source' accessible au public, donc notre base de donnée a été obtenue à partir de 'Kaggle'. Elle est composée de 3642 image IRM. On a vu ça dans le chapitre précédant. L'ensemble de données est distribué de manière aléatoire en ensembles d'apprentissage et en ensembles de test, manuellement, où l'ensemble d'apprentissage est divisé en deux sous-ensembles d'une manière aléatoire, automatiquement: un sous-ensemble pris en compte pour l'entraînement du Réseau, un sous-ensemble appliqué pour l'évaluation de la performance de la formation, c'est-à-dire la validation, et l'ensemble de test.

Le sous-ensemble de validation représente 20 pour cent de l'ensemble de données d'entraînement, ces données sont utilisées pour valider les performances d'entraînement, les données de test sont conservés pour valider les performances du classificateur, il ne participe pas au processus d'apprentissage. Ces ensembles de données ne sont pas exposés au classificateur.

## 4.3 Environnement de développement de système

### 4.3.1 Environnement matériel

L'apprentissage profond ou le deep learning est un terme désigne l'ensemble des techniques d'apprentissage automatique, autrement dit une forme d'apprentissage fondée sur des approches mathématiques utilisées pour modéliser des données, avec des exigences en calculs intenses et la disponibilité des ressources surtout GPU 'graphical processing unit' 'unité de traitement graphique', est plus puissant et peut effectuer des tâches spécifiques très rapidement, offre un parallélisme massif idéal pour les tâches répétitives et hautement parallèles.

Notre travail est réalisé sur :

- Un PC dont la configuration est :
  - PC portable : hp ProBook 4540s, (RAM) : 4.00 Go.
  - Microprocesseur : Intel(R) Core (TM) i3-3110M CPU @ 2.40GHz 2.40GHz.
  - Disque dur : 680 Go.
  - Type du système : Système d'exploitation 64 bits.
- Google Compute Engine backend (GPU)  
RAM : 1.13GB/12.68GB Disk : 38.69GB/78.19GB.

### 4.3.2 Environnement logiciel

Voici une liste de différentes plateformes et outils utilisés pour l'implémentation de notre système :

#### 4.3.2.1 Le langage de programmation utilisé (Python)



Apparu en 1990 par Guido van Rossum, développé par Python Software Fondation. C'est un langage de programmation objet et multiplateforme. Il favorise la programmation impérative et orienté objet, il est doté d'un typage dynamique fort, une gestion automatique de la mémoire, il fonctionne sur la plupart des plateformes informatiques. Il est conçu pour optimiser la productivité de programme en offrant des outils du haut niveau et une syntaxe plus simple a utilisée. Plusieurs Framework open sources sont disponibles dans la littérature la grande majorité supporte le langage Python. [39] Nous avons utilisé dans notre travail la version de Python 3.8, PyCharm Community Edition 2022.1.1.

### 4.3.2.2 Kaggle

Kaggle, une filiale de Google LLC, est une communauté en ligne de data scientists et de praticiens de l'apprentissage automatique. Kaggle permet aux utilisateurs de rechercher et de publier des ensembles de données, d'explorer et de créer des modèles dans un environnement de science des données basé sur le Web, de travailler avec d'autres scientifiques des données et ingénieurs en apprentissage automatique et de participer à des concours pour résoudre les défis de la science des données. Faites-nous une faveur Kaggle Kernels et c'est un atelier basé sur le cloud pour la science des données et l'apprentissage automatique. Permet aux data scientists de partager du code et des analyses en Python. [37]



### 4.3.2.3 Les bibliothèques Python

#### - TensorFlow TensorFlow

TensorFlow est un framework de programmation pour le calcul numérique qui a été rendu Open Source par Google en Novembre 2015. Depuis son release, TensorFlow n'a cessé de gagner en popularité, pour devenir très rapidement l'un des frameworks les plus utilisés pour le deep learning et donc les réseaux de neurones. Son nom est notamment inspiré du fait que les opérations courantes sur des réseaux de neurones sont principalement faites via des tables de données multidimensionnelles, appelées Tenseurs (Tensor). Un Tensor à deux dimensions est l'équivalent d'une matrice. Aujourd'hui, les principaux produits de Google sont basés sur TensorFlow: Gmail, Google Photos, Reconnaissance de voix. [2]

#### - Keras Keras

Keras est une API de réseaux de neurones de haut niveau, écrite en Python et capable de fonctionner sur TensorFlow ou Theano. Il a été développé en mettant l'accent sur l'expérimentation rapide. Être capable d'aller de l'idée à un résultat avec le moins de délai possible est la clé pour faire de bonnes recherches. Il a été développé dans le cadre de l'effort de recherche du projet ONEIROS (Open-ended Neuro-Electronic Intelligent Robot Operating System), et son principal auteur et mainteneur est François Chollet, un ingénieur Google. En 2017, l'équipe TensorFlow de Google a décidé de soutenir Keras dans la bibliothèque principale de TensorFlow. Chollet a expliqué que Keras a été conçue comme une interface plutôt que comme un cadre d'apprentissage end to end. Il présente un ensemble d'abstractions de niveau supérieur et plus intuitif qui facilitent la configuration des réseaux neuronaux

indépendamment de la bibliothèque informatique de backend. Microsoft travaille également à ajouter un backend CNTK à Keras aussi. [2]

- **Numpy**  NumPy

NumPy est une bibliothèque pour langage de programmation Python, destinée à manipuler des matrices ou tableaux multidimensionnels ainsi que des fonctions mathématiques opérant sur ces tableaux. [5]

- **OpenCV**  OpenCV

OpenCV est une bibliothèque graphique libre, initialement développée par Intel spécialisée dans le traitement d'images en temps réel. La société de robotique Willow Garage et la société ItSeez se sont succédé au support de cette bibliothèque. [6]

- **Matplotlib**  matplotlib

Matplotlib est une bibliothèque du langage de programmation Python destinée à tracer et visualiser des données sous formes de graphiques. Elle peut être combinée avec les bibliothèques python de calcul scientifique NumPy et SciPy. [9]

- **Flask**  Flask

Flask est un micro framework open-source de développement web en Python. Il est classé comme microframework car il est très léger. Flask a pour objectif de garder un noyau simple mais extensible. [13]

#### 4.3.2.4 Google Colab

Colaboratory, souvent raccourci en "Colab", est un produit de Google Research. Colab permet à n'importe qui d'écrire et d'exécuter le code Python de son choix par le biais du navigateur. C'est un environnement particulièrement adapté au machine learning, à l'analyse de données et à l'éducation. En termes plus techniques, Colab est un service hébergé de notebooks Jupyter qui ne nécessite aucune configuration et permet d'accéder sans frais à des ressources informatiques, dont des GPU. [30]

Nous avons utilisé Google Colab dans notre implémentation, parce que Cette plateforme permet d'entraîner des modèles de Deep Learning.

## 4.4 Implémentation et résultat

### 4.4.1 Paramètres d'entraînement

#### - Epoques (Epochs)

Une époque d'apprentissage signifie que l'algorithme d'apprentissage a effectué un passage dans l'ensemble de données d'apprentissage, où les exemples ont été séparés en groupes de «taille de lot» (batch size). [17]

#### - La Précision (Accuracy)

La moyenne des performances d'un modèle sur plusieurs exécutions donne une idée des performances moyennes du modèle spécifique sur l'ensemble de données spécifique. L'écart ou l'écart type des scores donne une idée de la variance introduite par l'algorithme d'apprentissage. [17]

#### - Fonction de perte (Loss)

Pour évaluer la qualité d'un modèle de réseau de neurones, c'est-à-dire trouver les valeurs  $w$  et  $b$  qui correspondent à notre modèle minimisant la fonction cout. L'objectif est de faire comprendre au modèle que sa prédiction est satisfaisante ou non. [31]

#### - Batch normalization

Il est connu depuis longtemps que l'apprentissage du réseau converge plus rapidement si ses entrées sont centrées réduites (moyenne = 0, variance = 1). Comme chaque couche observe des entrées produites par des couches qui la précèdent, il serait avantageux d'obtenir des entrées centrées et réduites pour chaque couche. Batch normalization est une composante qui se trouve entre les couches du réseau de neurones et qui prend continuellement la sortie d'une couche particulière et la normalise avant de l'envoyer à la couche suivante comme entrée. [12]

#### - Dropout

Le Dropout est une technique où des neurones sélectionnés au hasard sont ignorés (temporairement) pendant l'apprentissage. Cela signifie que leur contribution à l'activation des neurones qui leur succède est temporairement supprimé lors de la phase de propagation et toutes les mises à jour de poids ne sont pas appliquées au neurone lors de la phase de retro propagation. Lorsque des neurones sont supprimés au hasard du réseau pendant l'apprentissage, les autres neurones devront intervenir et gérer la représentation requise pour faire des prédictions pour les neurones manquants. Lors de la phase d'apprentissage, pour chaque itération, un neurone est gardé avec une probabilité  $p$ , sinon il est supprimé.

Lors de la phase de test, tous les neurones sont gardés, nous voulons donc que les sorties des neurones au moment du test soient identiques à leurs sorties au moment de l'apprentissage. Par exemple, dans le cas où  $p = 0.5$ , les neurones doivent réduire de moitié leurs sorties au moment du test pour avoir la même sortie que pendant l'apprentissage. [12]

#### - Optimizer Adam

Le nom Adam est dérivé de l'estimation adaptative du moment (adaptive moment estimation). C'est un algorithme pour l'optimisation du gradient de premier ordre des fonctions objectives, basé sur des estimations adaptatives des moments d'ordre inférieur. [17]

#### - Optimizer SGD

L'algorithme du gradient stochastique qui est donc une méthode de descente de gradient itérative optimisée. Cette méthode est la méthode de SGD avec moment qui conserve en mémoire la mise-à-jour à chaque étape, et calcule la suivante comme une combinaison convexe du gradient actuel et de la modification précédente. [31]

### 4.4.2 Prétraitement des données

Après l'importation et l'installation de bibliothèques python nécessaires, et l'importation de la base de données depuis google drive, nous avons effectué des prétraitements sur les données d'apprentissage et de validation pour former le réseau CNN plus efficacement. Ces prétraitements sont effectués en appliquant les opérations suivantes :

- Etiqueter les données de la base de donnée par : 0 et 1, ou 0 pour les images IRM en absence d'une tumeur, et 1 pour les images IRM en présence d'une tumeur.
- Redimensionnement de toutes les images IRM en même taille (160x160x3).
- Mélanger toutes les images IRM d'une façon aléatoire.
- La division de la base de données en deux ensembles, le premier 80% de la base pour l'entraînement et le deuxième 20% pour la validation, aléatoirement.

- Redimensionnement des images et la division de la base de données

```

x_train = []
y_train = []
image_size = 160
labels = ['glioma_tumor', 'meningioma_tumor', 'pituitary_tumor']
for i in labels:
    folderPath = os.path.join('/content/gdrive/My Drive/data/Training', i)
    for j in os.listdir(folderPath):
        img = cv2.imread(os.path.join(folderPath, j))
        img = cv2.resize(img, (image_size, image_size))
        x_train.append(img)
        y_train.append(1)

for i in labels:
    folderPath = os.path.join('/content/gdrive/My Drive/data/Testing', i)
    for j in os.listdir(folderPath):
        img = cv2.imread(os.path.join(folderPath, j))
        img = cv2.resize(img, (image_size, image_size))
        x_train.append(img)
        y_train.append(1)

labels = ['no_tumor']
for i in labels:
    folderPath = os.path.join('/content/gdrive/My Drive/data/Training', i)
    for j in os.listdir(folderPath):
        img = cv2.imread(os.path.join(folderPath, j))
        img = cv2.resize(img, (image_size, image_size))
        x_train.append(img)
        y_train.append(0)
    
```

Figure 4.1 – Etiquette et redimensionnement des images IRM.

```

[ ] x_train, y_train = shuffle(x_train, y_train, random_state=101)
x_train.shape

(3214, 160, 160, 3)

[ ] x_train, x_test, y_train, y_test = train_test_split(x_train, y_train, test_size=.2, random_state= 101)
# for i in enumerate(x_train):
# x_train = normalize(x_train)
# x_train = np.array(x_train)
    
```

Figure 4.2 – La division de la base de données.

- Recadrages des images IRM (Crop).

Nous avons expliqué le recadrage dans le chapitre précédent.

```

def crop_contour_RMI(image, plot=False):
    new_x_train = []
    # plot=False

    for i, image in enumerate(x_train):
        for j, image in enumerate(x_test):
            #im = ndarray: grayscale | y Drive/Dataset/' + 'yes/' + 'y1200.jpg')
            #i
            ndarray with shape (160, 160) | v2.COLOR_RGB2GRAY
            grayscale = cv2.GaussianBlur(grayscale, (5, 5), 0)

            # threshold the image, then perform a series of erosions +
            # dilations to remove any small regions of noise
            thresh = cv2.threshold(grayscale, 45, 255, cv2.THRESH_BINARY)[1]
            thresh = cv2.erode(thresh, None, iterations=2)
            thresh = cv2.dilate(thresh, None, iterations=2)

            # find contours in thresholded image, then grab the largest one
            contour = cv2.findContours(thresh.copy(), cv2.RETR_EXTERNAL, cv2.CHAIN_APPROX_SIMPLE)
            contour = imutils.grab_contours(contour)
            c = max(contour, key=cv2.contourArea)

            # find the extreme points
            extreme_pts_Left = tuple(c[c[:, :, 0].argmin()][0])
            extreme_pts_Right = tuple(c[c[:, :, 0].argmax()][0])
            extreme_pts_Top = tuple(c[c[:, :, 1].argmin()][0])
            extreme_pts_Bot = tuple(c[c[:, :, 1].argmax()][0])

            #ADD PIXELS = add pixels value
    
```

Figure 4.3 – Le recadrage des images IRM.




Figure 4.4 – Un exemple d’une image IRM avant et après Crop.

- **Augmentation de la base de données**

Nous avons expliqué le recadrage dans le chapitre précédent.

```
[x]
x=x.reshape((1,) + x.shape)
i=0
for patch in demo_datagen.flow(x, batch_size=1, save_to_dir='/content/gdrive/My Drive/preview1/', save_prefix='aug_img_yes', save_format='jpg'):
    i += 1
    if i > 10:
        break
plt.imshow(X1_train[30])
plt.xticks([])
plt.yticks([])
plt.title('Original Image')
plt.show()
plt.figure(figsize=(15,6))
i=1
for image in os.listdir('/content/gdrive/My Drive/preview1/'):
    image=cv2.imread('/content/gdrive/My Drive/preview1/' + image)
    image=cv2.cvtColor(image, cv2.COLOR_BGR2RGB)
    plt.subplot(3,7,i)
    plt.imshow(image)
    plt.xticks([])
    plt.yticks([])
    i +=1
    if i > 11:
        break
plt.suptitle('Augemented Images')
plt.show()
#j +=1
```

Figure 4.5 – L’augmentation de la base de données.

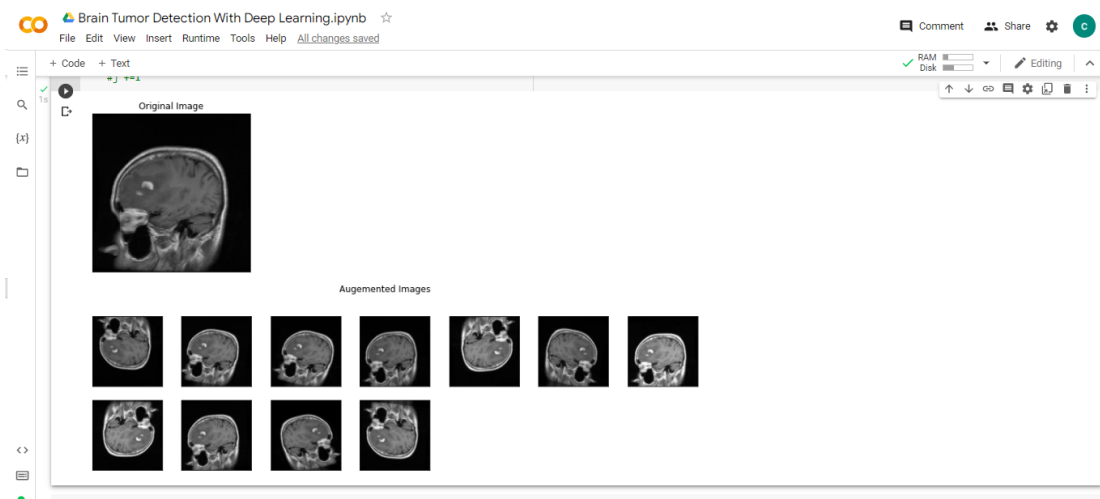


Figure 4.6 – Un exemple d’une image IRM avant et après l’augmentation.

### 4.4.3 Architecture de réseau

Nous allons commencer par entraîner un réseau de neurones convolutif classique. Les données d’entraînement ont été prétraitées (avec seulement étiquette, redimensionnement



mélange, et diviser l'ensemble de données). Le réseau possède des paramètres entraînables et il consiste en 5 couches convolutives, une couche de Batch\_Normalization, et de Max\_pooling sont placées après chaque couche convolutives et enfin un MLP à 2 couches ReLu sera la fonction d'activation. Sigmoid sera la fonction d'activation de la couche de sortie.

Notre hyper paramètre : Le nombre d'époque est égale à 30, Batch size est égal à 32, et en utilisant Adam comme optimizer, après le SGD optimizer.

- La création du modèle

```

Model: "sequential"
-----
Layer (type)                Output Shape              Param #
-----
conv2d (Conv2D)             (None, 160, 160, 16)     448
batch_normalization (Batch Normalization) (None, 160, 160, 16)     64
activation (Activation)     (None, 160, 160, 16)     0
max_pooling2d (MaxPooling2D) (None, 80, 80, 16)       0
conv2d_1 (Conv2D)           (None, 80, 80, 32)       4640
batch_normalization_1 (Batch Normalization) (None, 80, 80, 32)       128
activation_1 (Activation)   (None, 80, 80, 32)       0
max_pooling2d_1 (MaxPooling2D) (None, 40, 40, 32)       0
conv2d_2 (Conv2D)           (None, 40, 40, 64)       18496
batch_normalization_2 (Batch Normalization) (None, 40, 40, 64)       256
activation_2 (Activation)   (None, 40, 40, 64)       0
max_pooling2d_2 (MaxPooling2D) (None, 20, 20, 64)       0
conv2d_3 (Conv2D)           (None, 20, 20, 128)      73856
batch_normalization_3 (Batch Normalization) (None, 20, 20, 128)      512
activation_3 (Activation)   (None, 20, 20, 128)       0
max_pooling2d_3 (MaxPooling2D) (None, 10, 10, 128)       0
conv2d_4 (Conv2D)           (None, 10, 10, 256)      295168
batch_normalization_4 (Batch Normalization) (None, 10, 10, 256)     1024
activation_4 (Activation)   (None, 10, 10, 256)       0
max_pooling2d_4 (MaxPooling2D) (None, 5, 5, 256)         0
flatten (Flatten)           (None, 6400)              0
dense (Dense)               (None, 256)               1638656
dense_1 (Dense)             (None, 1)                 257
activation_5 (Activation)   (None, 1)                 0
-----
Total params: 2,033,505
Trainable params: 2,032,513
Non-trainable params: 992

'history = model.fit(x_train, y_train, batch_size=32, \n verbose=1, epochs=epochs, \n validation_data=(x_test, y_test), shuffle=False)\nmodel.save('BrainTumorD
etection10Epochs.h5')'
    
```

Figure 4.7 – La création du modèle.

- Adam optimizer
- L'apprentissage et le sauvegarde du modèle

```

[41] Epoch 2/30
81/81 [=====] - 2s 24ms/step - loss: 0.3996 - accuracy: 0.8829 - val_loss: 0.5636 - val_accuracy: 0.7294
Epoch 3/30
81/81 [=====] - 2s 24ms/step - loss: 0.3430 - accuracy: 0.9016 - val_loss: 0.3643 - val_accuracy: 0.8491
Epoch 4/30
81/81 [=====] - 2s 24ms/step - loss: 0.2304 - accuracy: 0.9261 - val_loss: 0.8869 - val_accuracy: 0.6423
Epoch 5/30
81/81 [=====] - 2s 24ms/step - loss: 0.1018 - accuracy: 0.9611 - val_loss: 1.1723 - val_accuracy: 0.5086
Epoch 6/30
81/81 [=====] - 2s 24ms/step - loss: 0.0684 - accuracy: 0.9743 - val_loss: 0.4122 - val_accuracy: 0.8414
Epoch 7/30
81/81 [=====] - 2s 24ms/step - loss: 0.0581 - accuracy: 0.9794 - val_loss: 0.1243 - val_accuracy: 0.9549
Epoch 8/30
81/81 [=====] - 2s 24ms/step - loss: 0.0892 - accuracy: 0.9685 - val_loss: 0.0909 - val_accuracy: 0.9673
Epoch 9/30
81/81 [=====] - 2s 24ms/step - loss: 0.0690 - accuracy: 0.9759 - val_loss: 0.1056 - val_accuracy: 0.9627
Epoch 10/30
81/81 [=====] - 2s 24ms/step - loss: 0.0591 - accuracy: 0.9778 - val_loss: 0.3202 - val_accuracy: 0.9082
Epoch 11/30
81/81 [=====] - 2s 24ms/step - loss: 0.0664 - accuracy: 0.9782 - val_loss: 0.1024 - val_accuracy: 0.9767
Epoch 12/30
81/81 [=====] - 2s 24ms/step - loss: 0.0291 - accuracy: 0.9887 - val_loss: 0.1084 - val_accuracy: 0.9627
Epoch 13/30
81/81 [=====] - 2s 24ms/step - loss: 0.0122 - accuracy: 0.9957 - val_loss: 0.0774 - val_accuracy: 0.9767
Epoch 14/30
81/81 [=====] - 2s 26ms/step - loss: 0.0141 - accuracy: 0.9969 - val_loss: 0.2099 - val_accuracy: 0.9316
Epoch 15/30
81/81 [=====] - 2s 25ms/step - loss: 0.0093 - accuracy: 0.9977 - val_loss: 0.2821 - val_accuracy: 0.9191
Epoch 16/30
81/81 [=====] - 2s 24ms/step - loss: 0.0055 - accuracy: 0.9977 - val_loss: 0.1362 - val_accuracy: 0.9751
Epoch 17/30
81/81 [=====] - 2s 24ms/step - loss: 0.0018 - accuracy: 0.9996 - val_loss: 0.1058 - val_accuracy: 0.9767
Epoch 18/30
81/81 [=====] - 2s 24ms/step - loss: 0.0084 - accuracy: 0.9969 - val_loss: 0.1164 - val_accuracy: 0.9767
Epoch 19/30
81/81 [=====] - 2s 24ms/step - loss: 0.0312 - accuracy: 0.9907 - val_loss: 0.2602 - val_accuracy: 0.9347
Epoch 20/30
81/81 [=====] - 2s 24ms/step - loss: 0.0273 - accuracy: 0.9891 - val_loss: 0.1106 - val_accuracy: 0.9736
Epoch 21/30
81/81 [=====] - 2s 24ms/step - loss: 0.0098 - accuracy: 0.9961 - val_loss: 0.1673 - val_accuracy: 0.9627
Epoch 22/30
81/81 [=====] - 2s 24ms/step - loss: 0.0071 - accuracy: 0.9973 - val_loss: 0.1815 - val_accuracy: 0.9689
Epoch 23/30
81/81 [=====] - 2s 24ms/step - loss: 0.0032 - accuracy: 0.9996 - val_loss: 0.1106 - val_accuracy: 0.9751
Epoch 24/30
81/81 [=====] - 2s 24ms/step - loss: 3.4641e-04 - accuracy: 1.0000 - val_loss: 0.0983 - val_accuracy: 0.9782
Epoch 25/30
81/81 [=====] - 2s 24ms/step - loss: 9.0698e-05 - accuracy: 1.0000 - val_loss: 0.0992 - val_accuracy: 0.9782
Epoch 26/30
81/81 [=====] - 2s 24ms/step - loss: 6.9587e-05 - accuracy: 1.0000 - val_loss: 0.1000 - val_accuracy: 0.9782
Epoch 27/30
81/81 [=====] - 2s 24ms/step - loss: 5.8396e-05 - accuracy: 1.0000 - val_loss: 0.1010 - val_accuracy: 0.9782
Epoch 28/30
81/81 [=====] - 2s 24ms/step - loss: 5.0477e-05 - accuracy: 1.0000 - val_loss: 0.1019 - val_accuracy: 0.9782
Epoch 29/30
81/81 [=====] - 2s 24ms/step - loss: 4.4426e-05 - accuracy: 1.0000 - val_loss: 0.1027 - val_accuracy: 0.9782
Epoch 30/30
81/81 [=====] - 2s 24ms/step - loss: 3.9606e-05 - accuracy: 1.0000 - val_loss: 0.1036 - val_accuracy: 0.9782
0s completed at 7:47 PM
    
```

Figure 4.8 – L'apprentissage (adam optimizer).

- La perte (loss) et la précision (accuracy) du réseau

```

Epoch 16/30
81/81 [=====] - 2s 24ms/step - loss: 0.0055 - accuracy: 0.9977 - val_loss: 0.1362 - val_accuracy: 0.9751
Epoch 17/30
81/81 [=====] - 2s 24ms/step - loss: 0.0018 - accuracy: 0.9996 - val_loss: 0.1058 - val_accuracy: 0.9767
Epoch 18/30
81/81 [=====] - 2s 24ms/step - loss: 0.0084 - accuracy: 0.9969 - val_loss: 0.1164 - val_accuracy: 0.9767
Epoch 19/30
81/81 [=====] - 2s 24ms/step - loss: 0.0312 - accuracy: 0.9907 - val_loss: 0.2602 - val_accuracy: 0.9347
Epoch 20/30
81/81 [=====] - 2s 24ms/step - loss: 0.0273 - accuracy: 0.9891 - val_loss: 0.1106 - val_accuracy: 0.9736
Epoch 21/30
81/81 [=====] - 2s 24ms/step - loss: 0.0098 - accuracy: 0.9961 - val_loss: 0.1673 - val_accuracy: 0.9627
Epoch 22/30
81/81 [=====] - 2s 24ms/step - loss: 0.0071 - accuracy: 0.9973 - val_loss: 0.1815 - val_accuracy: 0.9689
Epoch 23/30
81/81 [=====] - 2s 24ms/step - loss: 0.0032 - accuracy: 0.9996 - val_loss: 0.1106 - val_accuracy: 0.9751
Epoch 24/30
81/81 [=====] - 2s 24ms/step - loss: 3.4641e-04 - accuracy: 1.0000 - val_loss: 0.0983 - val_accuracy: 0.9782
Epoch 25/30
81/81 [=====] - 2s 24ms/step - loss: 9.0698e-05 - accuracy: 1.0000 - val_loss: 0.0992 - val_accuracy: 0.9782
Epoch 26/30
81/81 [=====] - 2s 24ms/step - loss: 6.9587e-05 - accuracy: 1.0000 - val_loss: 0.1000 - val_accuracy: 0.9782
Epoch 27/30
81/81 [=====] - 2s 24ms/step - loss: 5.8396e-05 - accuracy: 1.0000 - val_loss: 0.1010 - val_accuracy: 0.9782
Epoch 28/30
81/81 [=====] - 2s 24ms/step - loss: 5.0477e-05 - accuracy: 1.0000 - val_loss: 0.1019 - val_accuracy: 0.9782
Epoch 29/30
81/81 [=====] - 2s 24ms/step - loss: 4.4426e-05 - accuracy: 1.0000 - val_loss: 0.1027 - val_accuracy: 0.9782
Epoch 30/30
81/81 [=====] - 2s 24ms/step - loss: 3.9606e-05 - accuracy: 1.0000 - val_loss: 0.1036 - val_accuracy: 0.9782
    
```

Figure 4.9 - La perte (loss) et la précision (accuracy) du réseau (adam optimizer).

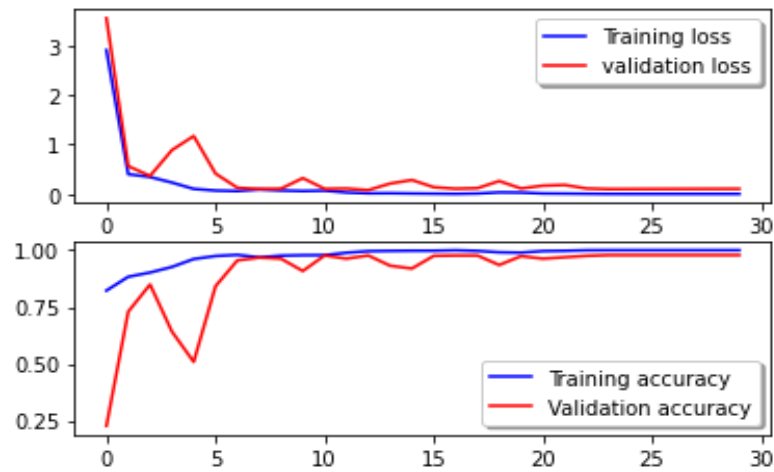


Figure 4.10 - La courbe de perte (loss) et la courbe de précision (accuracy) du réseau (adam optimizer).

- SGD optimizer

• L'apprentissage et le sauvegarde du modèle




Figure 4.11 – L'apprentissage (SGD optimizer).

• La perte (loss) et la précision (accuracy) du réseau



Figure 4.12 - La perte (loss) et la précision (accuracy) du réseau (SGD optimizer).



**Figure 4.13** - La courbe de perte (loss) et la courbe de précision (accuracy) du réseau (SGD optimizer).

#### 4.4.4 Résultat et discussion

##### 4.4.4.1 Adam optimizer

La première constatation est que le modèle arrive à s'entraîner correctement, il n'y a pas vraiment d'incohérence au niveau de l'entraînement, mais il y a d'incohérence au niveau de la validation. La précision pour l'entraînement tend vers **1,0**, en terme de probabilité, et la précision maximale pour la validation atteint **0,9782**.

##### 4.4.4.2 SGD optimizer

La première constatation est que le modèle arrive à s'entraîner correctement, il n'y a pas vraiment d'incohérence au niveau de l'entraînement et au niveau de la validation. L'écart entre la validation et l'entraînement entre l'époque 0, 2, et 3 est normal, car le modèle commence à apprendre les paramètres, et à partir de la sixième époque la précision ne cesse pas de s'accroître pour l'entraînement et la validation.

La précision pour l'entraînement tend vers **1,0**, en terme de probabilité, et la précision maximale pour la validation atteint **0,9782**. Une perte de gradient n'est pas constatée, et le modèle n'est pas compliqué, ce qui rend l'apprentissage plus vite. La bonne configuration de la taille de lots (batch size) nous a supprimé la fluctuation au niveau de notre résultat, l'erreur d'apprentissage est aussi vite et bien minimisée.

➤ Toutes les prochaines expérimentations se feront avec SGD comme algorithme d'apprentissage.

### 4.4.5 Ajout d'une couche Dropout a notre réseau

Nous allons introduire Dropout à notre modèle, après la couche entièrement connectée. Les résultats suivants sont obtenus :

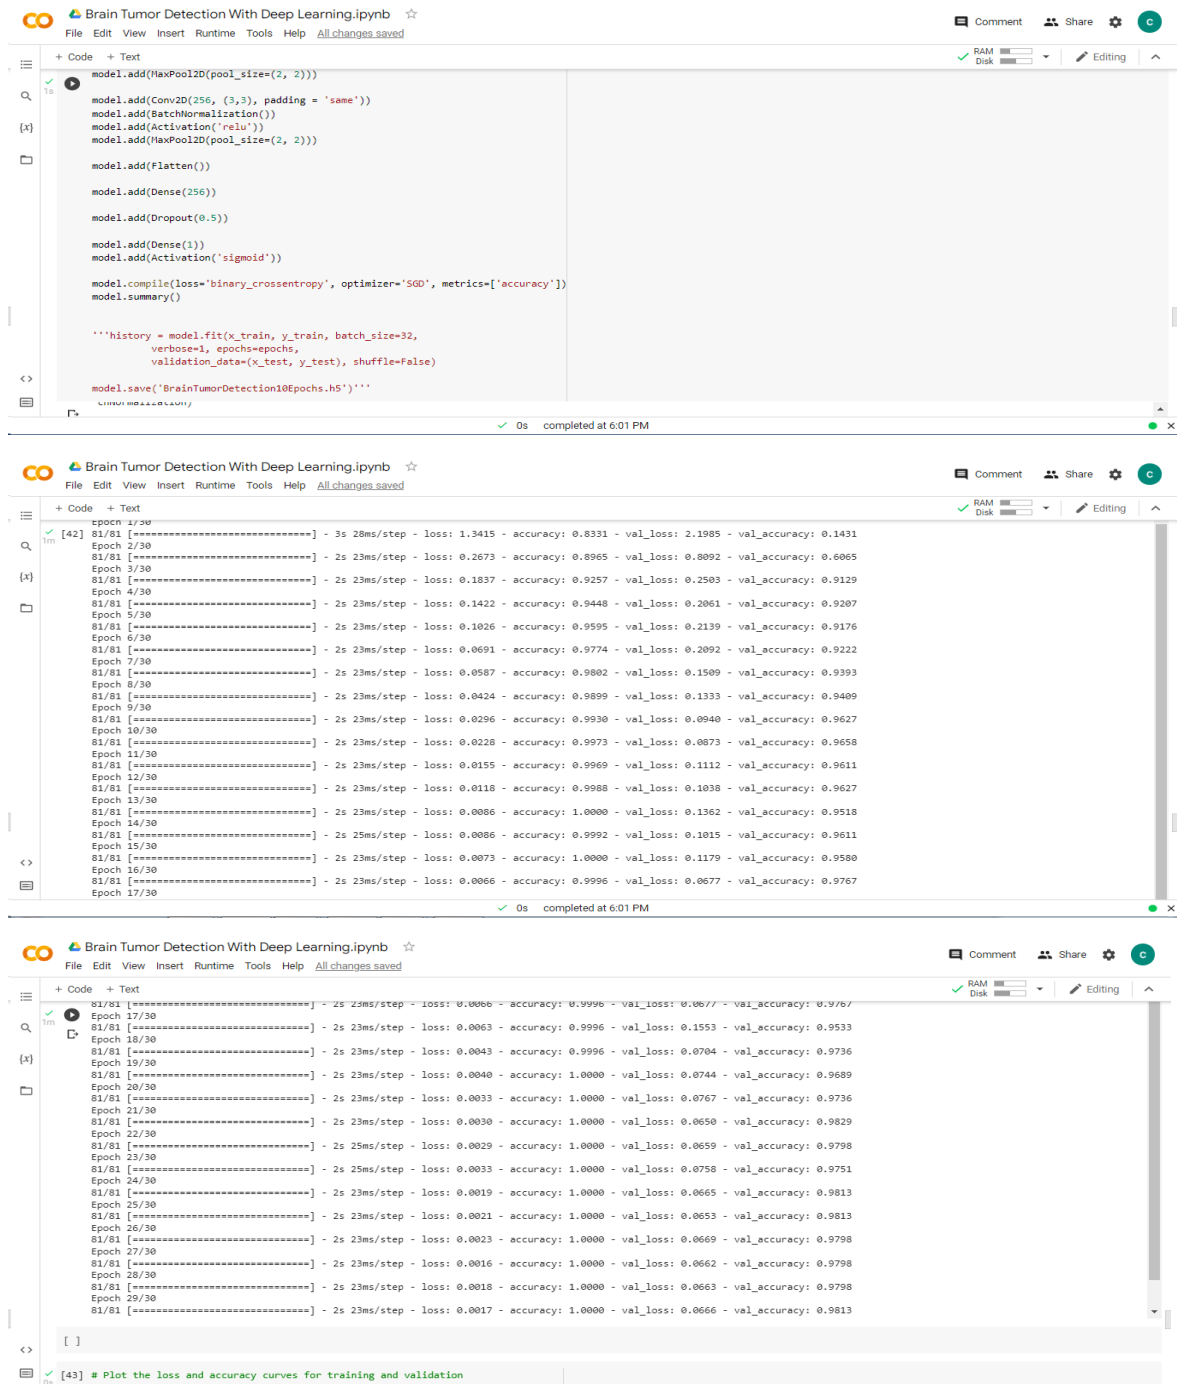


Figure 4.14 – Résultats obtenus Après Dropout, la précision maximale pour la validation atteint **0,9813**.

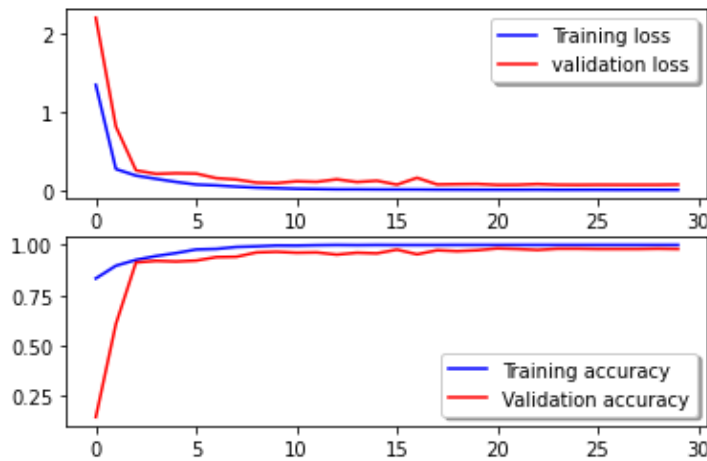


Figure 4.15 - La courbe de perte (loss) et la courbe de précision (accuracy) du réseau après Dropout.

#### 4.4.6 Recadrage des images IRM et les résultats obtenus

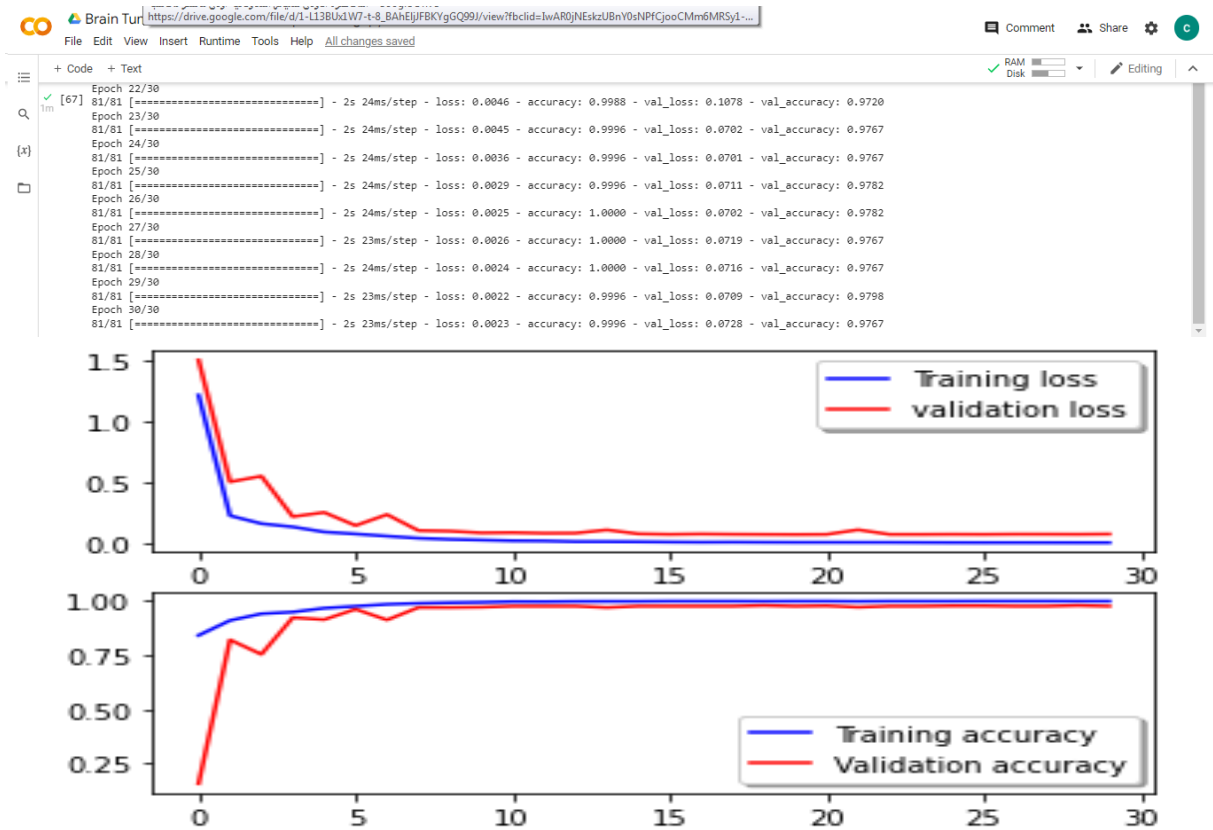


Figure 4.16 – Résultats obtenus et courbes Après Dropout, et recadrage des IRM, la précision maximale pour la validation atteint **0,9798**.



## 4.5 Le fonctionnement de l'application

L'application est sur PyCharm Community Edition 2022.1.1, Python 3.8

### 4.5.1 Prétraitement des données, création du modèle CNN, et apprentissage

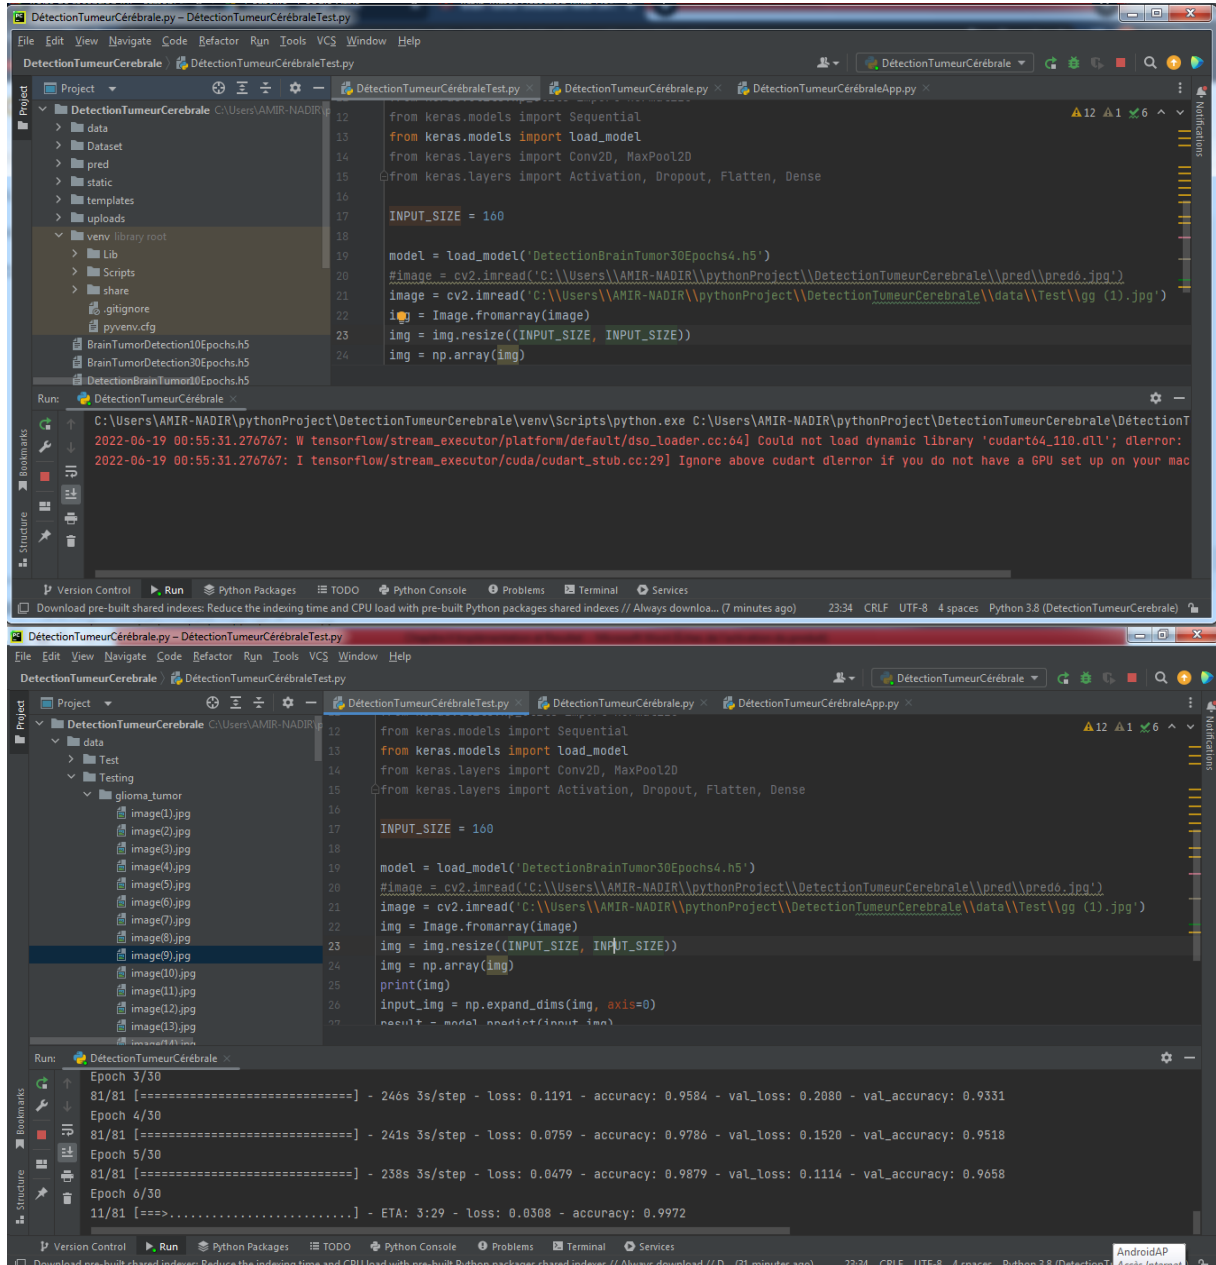


Figure 4.18 - Prétraitement des données, création du modèle CNN et apprentissage.



### 4.5.2 La courbe de perte (loss) et la courbe de précision (accuracy)

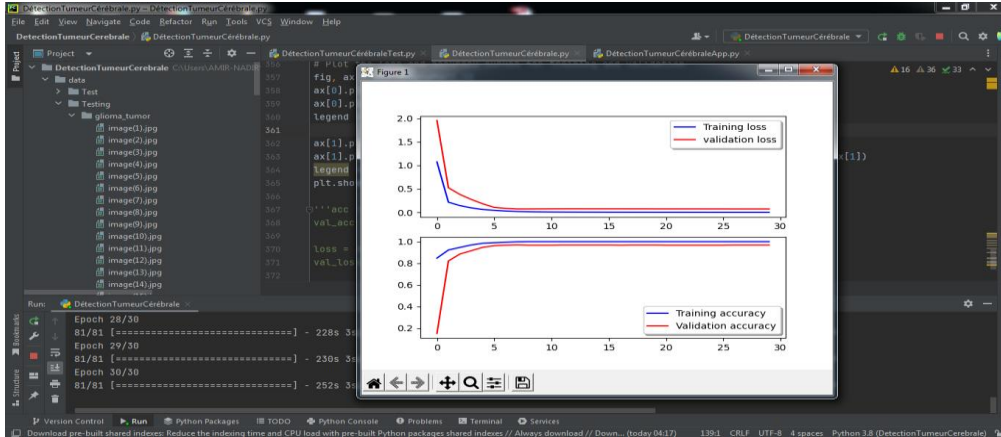


Figure 4.19 La courbe de perte (loss) et la courbe de précision (accuracy)

### 4.5.3 Partie de test

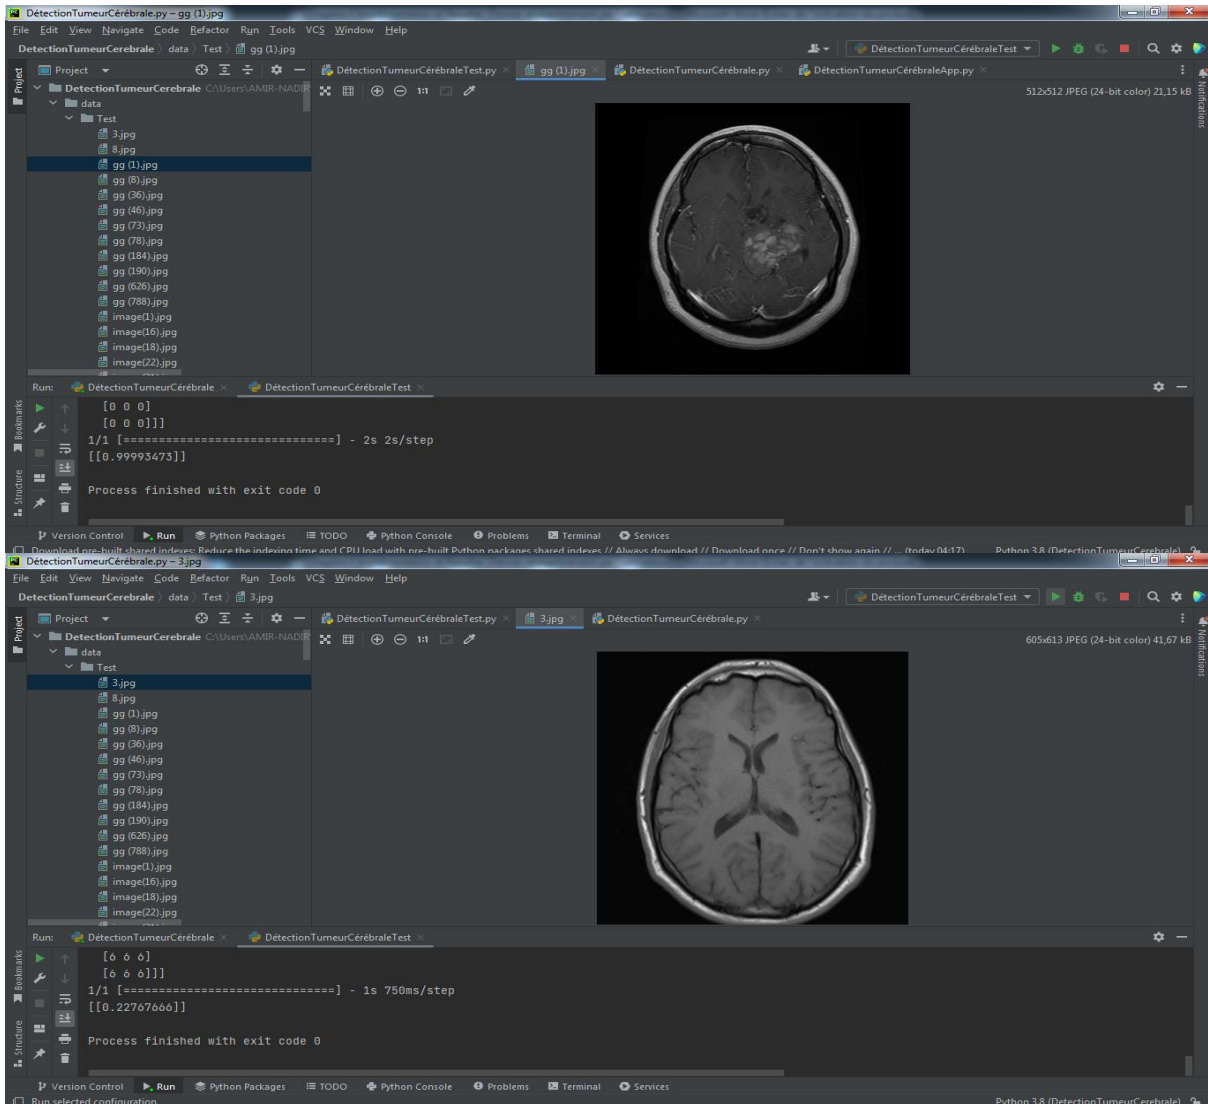
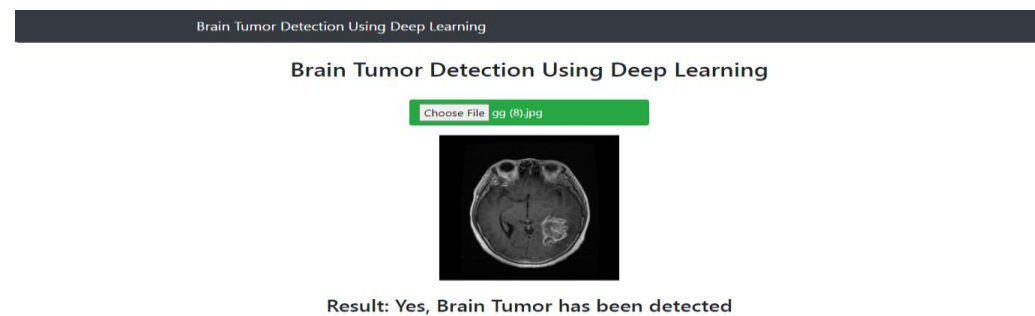
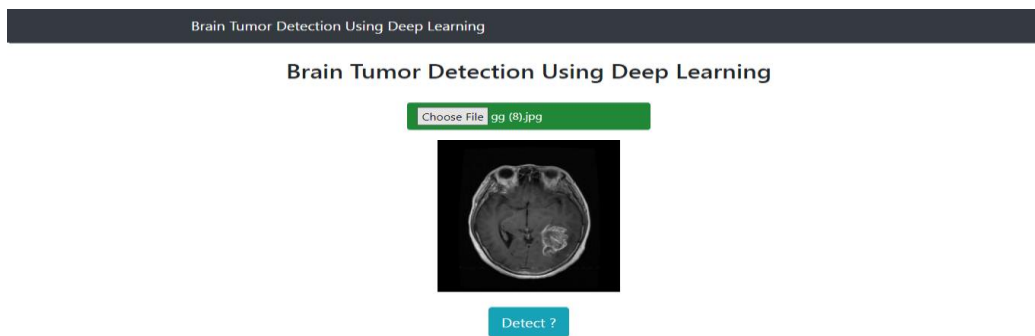
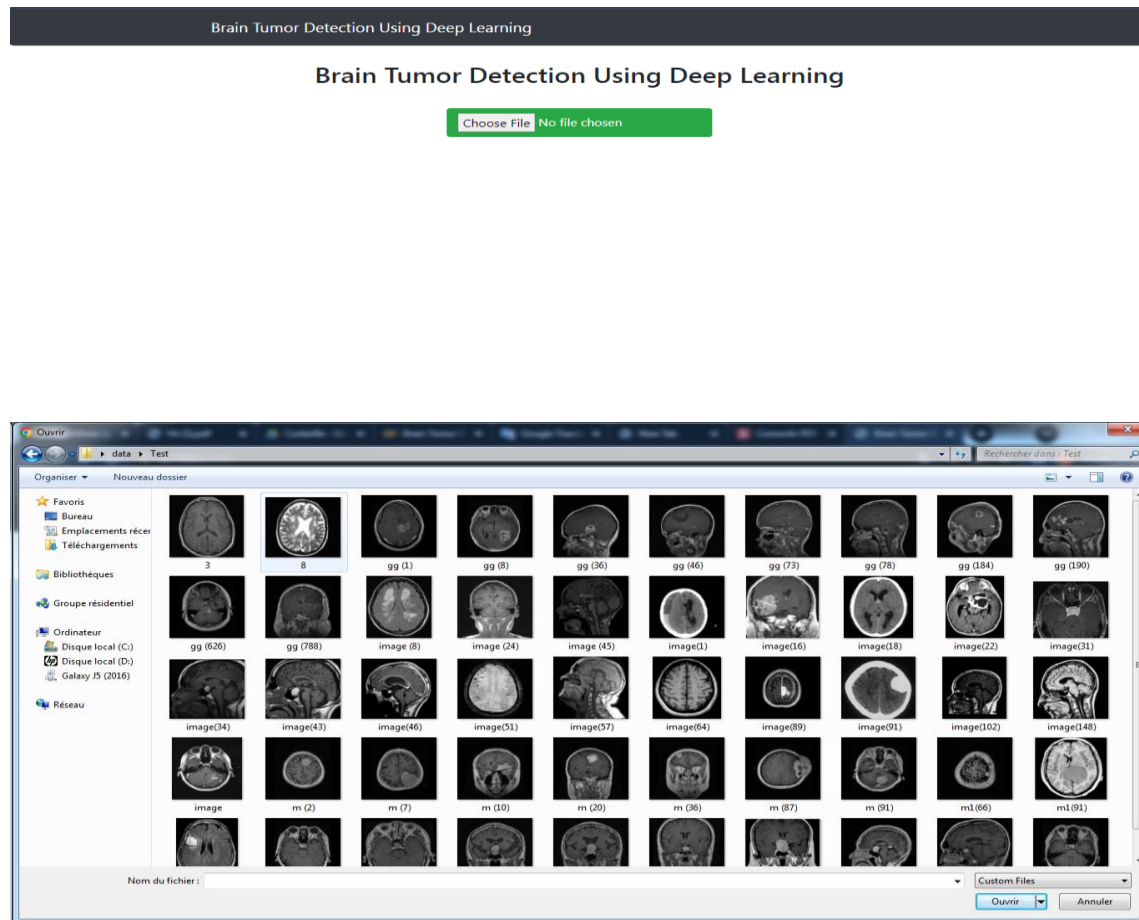


Figure 4.20 Deux exemples de test de deux images IRM, avec tumeur et sans tumeur.

### 4.5.4 Interface de l'application

Nous avons tenu à introduire notre réseau de neurones convolutif dans une interface graphique afin de pouvoir visualiser les performances de notre réseau.



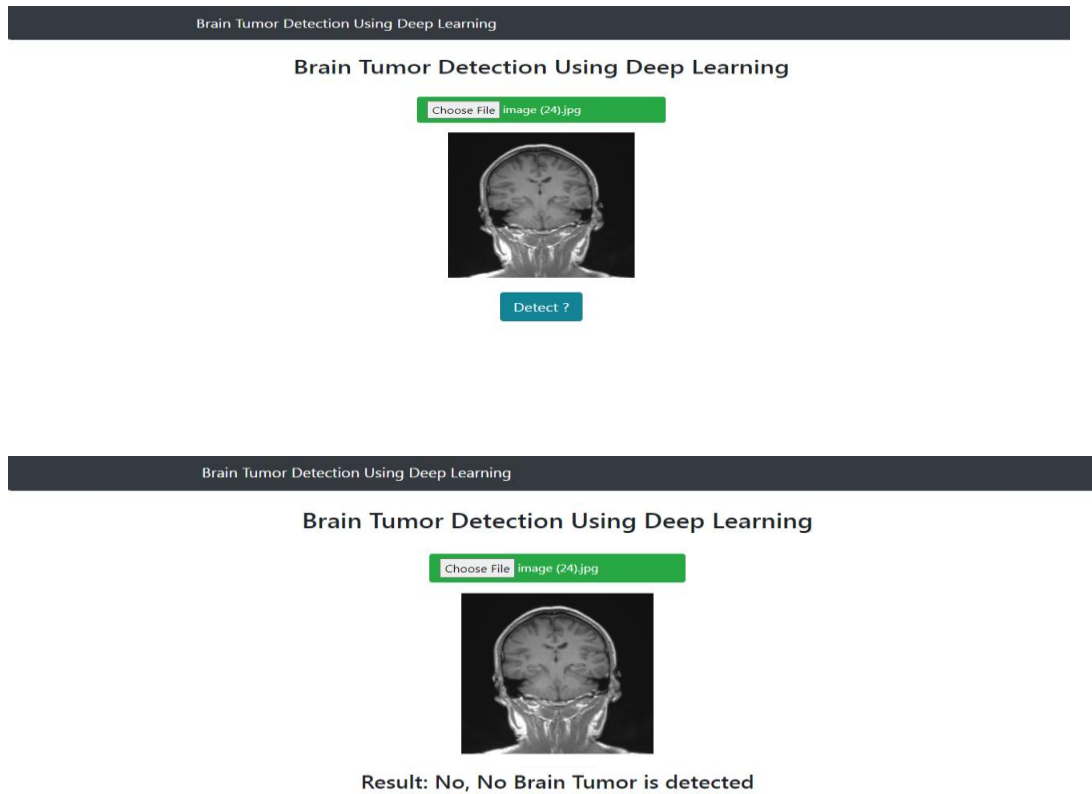


Figure 4.21 - Interface de l'application.

## 4.6 Travaux existants

Il existe plusieurs études sur la détection des tumeurs cérébrale, utilisant l'IRM qui ont été effectuées auparavant. L'ondelette discrète Transformée (DWT), Transformée en ondelettes continue (CWT), et les méthodes SVM (Support Vector Machine) sont utilisées pour détecter les tumeurs cérébrales. Cette méthode obtient des résultats suffisamment élevés pour détecter les tumeurs cérébrales ; cependant, il y a encore des faiblesses dans le calcul. Même si les résultats sont assez élevés, la configuration du modèle créé n'est pas incluse et le jeu de données n'est pas expliqué. La classification des tumeurs cérébrales à l'aide de méthodes d'apprentissage automatique a déjà été étudiée par les chercheurs, surtout ces dernières années. Le développement de l'intelligence artificielle et des nouvelles technologies basées sur l'apprentissage profond a eu un grand impact dans le domaine de l'analyse des images médicales, notamment dans le domaine du diagnostic des maladies (Mehmood et al. 2020 2021 ; Yaqub et al. 2020). En parallèle, de nombreuses études ont été menées sur la détection et la multi classification des tumeurs cérébrales à l'aide de CNN. Les chercheurs suivants ont adopté des modèles CNN pré-entraînés en utilisant une approche d'apprentissage par transfert pour la classification des tumeurs cérébrales. Par exemple :

- **Çinar et Yildirim (2020)** ont utilisé une forme modifiée du modèle CNN ResNet-50 pré-entraîné en remplaçant ses 5 dernières couches par 8 nouvelles couches pour la détection de tumeurs cérébrales. Ils ont obtenu une précision de **97,2 %** en utilisant des images IRM avec ce modèle CNN modifié.
- **S. Kevin Zhou, Hayit Greenspan, Dinggang Shen** ont écrit des livres concernant l'apprentissage profond pour l'analyse des images médicales. À part plusieurs articles écrits par des chercheurs comme celui de Ali ARI, Davut Hanbay, Justin Paul, plusieurs compétitions ont été réalisés afin d'avoir le maximum de précision pour une quantité de données limitées. [31]

## **4.7 Conclusion**

Dans ce chapitre on a présenté l'implémentation et l'application de notre système. Notre modèle présente une meilleure précision en termes d'entraînement et de validation, ces valeurs tendent vers 1 à une certaine époque. Une perte ou une explosion de gradient n'est pas constatée, et le modèle n'est pas compliqué. Dans ce travail, nous avons utilisé et élaboré les différentes techniques d'optimisation et de régularisation comme la normalisation de lot, le dropout, et la technique d'augmentation de données pour rendre notre modèle optimal et robuste. Nous avons utilisé plusieurs combinaisons pour choisir les nombres des couches, les nombres des filtres. Notre modèle peut atteindre une précision maximale de **98,861%**. Le modèle CNN proposé arrive à bien identifier les images de cerveau contenant une tumeur et les images normales d'un cerveau et possède une précision satisfaisante, sans fluctuation et rapide à apprendre.

# *Conclusion Générale*

Notre mémoire illustre une technique qui permet de détecter des tumeurs cérébrales à travers des images IRM, et cela en utilisant une méthode d'extraction de caractéristiques, et classification des images IRM, en se basant sur un algorithme d'apprentissage profond (Deep Learning).

Durant notre étude sur le domaine de deep learning, et l'imagerie médicale :

- Nous avons vu l'importance des images IRM pour la détection des tumeurs cérébrales et cela parce que l'IRM cérébrale est un examen qui permet de détecter des anomalies cérébrales et d'en déterminer la cause (vasculaire infectieuse, dégénérative inflammatoire ou tumorale). Ainsi, l'IRM permet de visualiser la partie superficielle (substance blanche) du cerveau.
- Nous allons nous focaliser sur un des algorithmes les plus performants du Deep Learning, les réseaux de neurones convolutifs CNN, les CNN sont spécialement conçus pour traiter des images en entrée. Leur architecture est alors plus spécifique : elle est composée de deux blocs principaux. Le premier bloc fait la particularité de ce type de réseaux de neurones, puisqu'il fonctionne comme un extracteur de caractéristiques.

Notre projet a été conçu comme suit :

- Un aperçu sur l'intelligence artificielle, ce domaine qui nous a permis éventuellement de découvrir la possibilité d'implémenter des systèmes artificiels intelligents pouvant réaliser des tâches humaines.
- Une étude détaillée sur la tumeur cérébrale et l'imagerie par résonance magnétique (IRM).
- Une étude brève sur les réseaux de neurones artificiels.
- Nous avons illustré en détails toute notion concernant l'apprentissage profond (Deep Learning), et les réseaux de neurones convolutifs CNN.
- Une conception approfondie où nous avons expliqué les différents sous-systèmes constituant notre projet, ainsi que le prétraitement des images IRM, la construction du modèle de réseau de neurone convolutif, vu sa nécessité dans la résolution de notre problématique.
- En dernier, nous avons détaillé l'implémentation de notre système en représentant les différentes structures de données ainsi que les fonctions employées dans notre logiciel. Ce dernier qui a été implémenté en utilisant l'environnement de Google Colab pour l'exécution de l'entraînement sur GPU, il est préférable d'utiliser un accélérateur graphique (GPU) qui est bien plus puissants que le CPU, et mieux adaptés à la grande quantité de calculs requise par les applications de Deep Learning et les bases de données énormes.

Une fois l'apprentissage réalisé avec succès, le modèle de réseau de neurones convolutif obtenu peut être utilisé sur une plateforme ayant un simple CPU. Comme nous avons fait dans notre implémentation. Les résultats obtenus sont acceptables.

Plusieurs perspectives peuvent être envisagées dans la prolongation de ce mémoire, nous pouvons citer :

- Tester d'autres bases de données plus grandes.
- Détection des tumeurs cérébrales par leur type.
- Détection des tumeurs cérébrales à partir des images IRM 3D.

# *Bibliographie*

- [1]: DJERIRI Youcef, chapitre : Les réseaux de neurones artificiels, 20-09- 2017.  
<https://fr.scribd.com/document/495288846/Polycopie-RNA>.
- [2]: MOKRI Mohammed Zakaria. Classification des images avec les réseaux de neurones Convolutionnels. Mémoire de fin d'études Pour l'obtention du diplôme de Master en informatique Option : Modèle Intelligent et Décision. Université de tlemcen, 03-07-2017.  
<http://dspace.univ-tlemcen.dz/bitstream/112/12235/1/Classification-des-images-avec-les-reseaux-de-neurones.pdf>.
- [3]: DJERIRI Youcef. Commande par réseaux de neurones d'une MADA intégrée à un système éolien. Département D'électronique Pour l'obtention du diplôme de: Magister en Électrotechnique OPTION : Conversion d'énergie et commande. Université djillali liabes de sidi bel-abbès, 13-12-2009.  
[https://www.academia.edu/31410530/Memoire\\_Magister\\_Y\\_DJERIRI?email\\_work\\_card=reading-history](https://www.academia.edu/31410530/Memoire_Magister_Y_DJERIRI?email_work_card=reading-history).
- [4]: HAJRAOUI Abdellatif. Contribution à la reconnaissance de visages humains. Thèse Pour l'obtention du grade de Docteur Spécialité : Informatique. Université sultan moulay slimane - Faculté des Sciences et Techniques Béni-Mellal, 21 -11-2015.  
[https://academia.edu/201912236/Contribution\\_à\\_la\\_reconnaissance\\_de\\_visages\\_humains](https://academia.edu/201912236/Contribution_à_la_reconnaissance_de_visages_humains).
- [5]: <http://fr.Wikipédia.org/wiki/Numpy>.
- [6]: <http://fr.Wikipédia.org/wiki/OpenCv>.
- [7]: BENSIAH Oussama Akram. La proposition d'une nouvelle approche basée Deep Learning pour la prédiction du cancer du sein. Mémoire de fin d'étude en vue de l'obtention du diplôme de Master En Informatique Spécialité : Architecture Distribuée. Université L'arbi Ben M'hidi Oum El Bouaghi 2019-2020.  
<https://bib.univ-ueb.dz:8080/jspui/bitstream/123456789/10507/1/V2.0Memoire20%Version%20finale%20bein%20remercement.pdf>.
- [8]: SAHLI Aoulia. Segmentation des images médicales par apprentissage profond. Mémoire de fin d'étude en vue d'obtention d'un diplôme de Master en Informatique.  
Domaine : Informatique Spécialité : Systèmes et Multimédias. Université de Tébessa, 2020-2021.



<http://dspace.univ-tebessa.dz:8080/xmlui/bitstream/handle/123456789/663/AOULIA.pdf?sequence=1&isAllowed=Y> SAHLI%20

[9]: <http://fr.Wikipédia.org/wiki/Matpolib>.

[10]: NACER Foued. Reconnaissance d'expression faciale à partir d'un visage réel. Mémoire de Fin d'études Master Filière : Informatique Option : Systèmes Informatiques. Université de 8 Mai 1945 Guelma, 07- 2019.

<http://dspace.univ-guelma.dz/jspui/bitstream/123456789/4326/1/PFE-2019%Nacer%20Foued%20%28Tchi%20drive2%29%20%281%29.pdf>.

[11]: <https://dspace.univ-bba.dz/bitstream/handle/123456789/1411/memoire.pdf?sequence=1&isAllowed=y>.

[12]: MOUALEK Djaloul Youcef. Deep Learning pour la classification des images. Mémoire de fin d'études pour l'obtention du diplôme de Master en Informatique Option: Modèle Intelligent et Décision(M.I.D)Université de Tlemcen, 03-07-2017.

<http://dspace.univ-telemcen.dz/bitstream/112/12583/1/Deep-Learning-pour-la-classification.pdf>.

[13]: [http://fr.Wikipédia.org/wiki/Flask\\_\(framework\)](http://fr.Wikipédia.org/wiki/Flask_(framework)).

[14]: Mr. BABAALI Baligh et Mr LAIB Hamza. Approche basée sur l'apprentissage profond pour la détection d'intrusion réseau. Projet de fin d'études Présenté pour l'obtention du Diplôme de Master en Informatique Option : Ingénierie des Systèmes et Technologies du Web. Université Yahia Fares – Medea, 2018-2019.

[https://academia.edu/40539749/Approche\\_basée\\_sur\\_l'apprentissage\\_profond\\_pour\\_la\\_détection\\_dintrusion\\_réseau?auto=download&email\\_work\\_card=download-paper](https://academia.edu/40539749/Approche_basée_sur_l'apprentissage_profond_pour_la_détection_dintrusion_réseau?auto=download&email_work_card=download-paper).

[15] : BEN LAZREG Mohsen. Recherche de l'information dans les réseaux de neurones convolutifs pré-entraînés. Ecole de technologie supérieure université du quebec, 02-10-2020.

[http://espace.etsmtl.ca/id/eprint/2637/1/BEN\\_LAZREG\\_Mohsen.pdf](http://espace.etsmtl.ca/id/eprint/2637/1/BEN_LAZREG_Mohsen.pdf).

[16] : [http://staff.univ-batna2.dz/sites/default/files/merzougui\\_ghalia/files/support\\_de\\_cours\\_-deep\\_learning-chapitre3-cnn.pdf](http://staff.univ-batna2.dz/sites/default/files/merzougui_ghalia/files/support_de_cours_-deep_learning-chapitre3-cnn.pdf).

[17] : KHERMAZA Elyes et BOUTIARA Abdelouahab. Traitement des images IRM pour la détection des tumeurs cérébrales par les algorithmes de Deep Learning CNN, Faster RCNN Mask R-CNN et Transfer Learning sous environnement Cloud. Mémoire de Master Filière Électronique Spécialité Électronique des Systèmes Embarqués. Universitaire blida, 2019-2020.

[http://di.univ-blida.dz:8080/jspui/bitstream/123456789/11334/1/Mémoire\\_Rectifié\\_Boutiara\\_Khermaza\\_%182%29.pdf](http://di.univ-blida.dz:8080/jspui/bitstream/123456789/11334/1/Mémoire_Rectifié_Boutiara_Khermaza_%182%29.pdf).

[18] : KAZI TANI (Ep. DALI YUCEF) Lamia Fatiha. Conception et Réalisation d'un Outil Semi-Automatique Dédié à l'Analyse et la Recherche du Contenu Vidéo du Web. En vue de l'obtention du diplôme de Doctorat en Sciences Spécialité : Ingénierie des Systèmes Complexes et Multimédia Université d'Oran, 24-06-2020.

<http://theses.univ-oran1.dz/document/TH5141.pdf>.

[19] : EL KOUCH Imane, Otman Abdoun. Détection du cancer du cerveau à l'aide d'un réseau de neurones. International Journal of Scientific & Engineering Research Volume 10 Issue 9 September-2019 ISSN 2229-5518.

<https://ijsr.org/researchpaper/Detection-du-cancer-du-cerveau-a-l-aide-reseau-de-neurones.pdf>.

[20] : Pr Khê Hoang-Xuan, neuro-oncologue, Dr Matthieu Peyre, neurochirurgien, Dr Loïc Feuvret radiothérapeute à l'hôpital de la Pitié-Salpêtrière (Paris). Les Cancers du cerveau collection comprendre et agir. Fondation ARC pour la recherche sur le cancer. 1er tirage 05- 2015.

[http://fondation-arc.org/sites/default/files/2017-06/brochure\\_cerveau.pdf](http://fondation-arc.org/sites/default/files/2017-06/brochure_cerveau.pdf).

[21] : Marcel Chatel, neuro-oncologue, CHU de Nice, Didier Frappaz, neuro-oncologue Centre Léon Bérard, Lyon, Philippe Menei, neurochirurgien, CHU d'Angers...etc. Les Tumeurs du cerveau. L'Institut national du cancer (INCa) est l'agence d'expertise sanitaire et scientifique en cancérologie chargée de coordonner la lutte contre les cancers en France. Juin 2010.

<http://www.e-cancer.fr>.

[22] : Prof. Pierre-Yves Dietrich, médecin adjoint, HUG, Genève Prof. Marc Levivier Directeur du Centre universitaire romand de neurochirurgie, CHUV, Lausanne Dr Olivier Vernet neurochirurgien, Lausanne Dr Roger Stupp, CHUV, Lausanne. Les tumeurs cérébrales et du système nerveux central. Une information de la Ligue contre le cancer pour les personnes concernées et leurs proches. © 2009, Ligue suisse contre le cancer, Berne.

[http://fragile.ch/fileadmin/user\\_upload/downloads/01\\_leben\\_mit\\_HV/Tumeurs\\_cérébrales\\_et\\_SNC.pdf](http://fragile.ch/fileadmin/user_upload/downloads/01_leben_mit_HV/Tumeurs_cérébrales_et_SNC.pdf).

[23] : Anne-Sophie Capelle-Laizé. Segmentation des images IRM multi-échocs tridimensionnelles pour la détection des tumeurs cérébrales par la théorie de l'évidence. Interface homme-machine [cs.HC]. Thèse pour l'obtention du Grade de Docteur de l'université de Poitiers (Faculté des Sciences Fondamentales et Appliquées) (Diplôme National - Arrêté du 25 avril 2002). Université de Poitiers, 2003.

<http://tel.archives-ouvertes.fr>.

[24] : MEZIANE Abdelfettah. Etude et comparaison des méthodes de segmentation d'images cérébrales. Mémoire pour l'obtention du diplôme de Magister en Informatique Option : IAAD (Intelligence Artificielle et Aide à la Décision). Université Abou-Bakr Belkaid-Tlemcen. 07- 2011.

<http://dspace.univ-telemcen.dz/bitstream/112/375/1/ etude-et- comparaison- des- methodes- de- segmentation- dimages- cerebrales.pdf>.

[25] : Kalpana U. Rathod and Prof. Y. D. Kapse. MRI Brain Tumor Detection Using Artificial Neural Network. International Journal of Current Research Vol. 8, Issue, 06 pp.33558-33564, 06- 2016.

[26] : Gopal S. Tandel, Mainak Biswas, al. 2019. A Review on a Deep Learning Perspective in Brain Cancer Classification.

[27] : Dr Maryam Asad-Syed, radiologue, IMAGIR, Bordeaux, Nicole Dispens, patiente Aubergenville, Michel Kauffmann, patient et bénévole du Comité de patients pour la recherche clinique en cancérologie de la Ligue contre le cancer, Pr Alain Luciani radiologue Hôpitaux universitaires, Henri Mondor, Université Paris-Est Créteil, apr.-HP membre du bureau de la Société française de radiologie...etc. L'imagerie par résonance magnétique (IRM). Institut National du Cancer. 09- 2020.

<http://onco-hdf.fr/app/uploads/2021/02/FicheIRM-2020.pdf>.

[28] : L.Germond. Trois principes de coopération pour la segmentation en imagerie de résonance magnétique cérébrale. Université Joseph Fourier 1999.

[29] : Minh Hong VU THI : développement d'une sonde peropératoire basée sur la détection d'auto fluorescence pour l'assistance au traitement chirurgical des tumeurs cérébrales Pour obtenir le titre de Docteur de l'Université Paris XI, le 28 -10- 2008.

[30] : <https://research.google.com/colaboratory/faq.html?hl=fr#:~:text=Colaboratory%2C%20souvent%20raccourci%20en%20%22Colab,donn%C3%A9es%20et%20%C3%A0%20l'%C3%A9ducation>.

[31] : Hasinavalona H. S. E.1, Randriamitantsoa P. A.2, Randriamitantsoa A. A.3 Modélisation par apprentissage profond pour contribuer au traitement de l'imagerie médicale application pour une classification binaire et multi classe d'une tumeur cérébrale. Université d'Antananarivo BP 1500, Ankatso – Antananarivo 101 – Madagascar, MADA-ETI, ISSN 2220-0673, Vol.2, 2021.

[www.madarevues.recherches.gov.mg/IMG/pdf/art\\_no05\\_2021\\_vol\\_2\\_pp\\_64-80\\_modelisation\\_par\\_apprentissage\\_profond\\_pour\\_contribuer\\_au\\_traitement\\_de\\_l\\_imagerie\\_medicale.pdf](http://www.madarevues.recherches.gov.mg/IMG/pdf/art_no05_2021_vol_2_pp_64-80_modelisation_par_apprentissage_profond_pour_contribuer_au_traitement_de_l_imagerie_medicale.pdf).

[32] : <https://www.mdpi.com/1424-8220/21/6/2222/htm>.

[33] : <https://github.com/sartajbhuvaji/brain-tumor-classification-dataset>.

[34] : [https://www.researchgate.net/figure/Architecture-of-convolutional-neural-network-using-medical-image-8\\_fig2\\_341152313](https://www.researchgate.net/figure/Architecture-of-convolutional-neural-network-using-medical-image-8_fig2_341152313).

[35] : [https://openclassrooms.com/fr/courses/4470531-classez-et-segmentez-des-donnees-visuelles/5083336-decouvrez-les-differentes-couches-dun-cnn?fbclid=IwAR2dAKa1X41tUomGx2TqnUSLxRTEqcl4mPt8fLjAhsWUWN2pIKH\\_zLXcGqw](https://openclassrooms.com/fr/courses/4470531-classez-et-segmentez-des-donnees-visuelles/5083336-decouvrez-les-differentes-couches-dun-cnn?fbclid=IwAR2dAKa1X41tUomGx2TqnUSLxRTEqcl4mPt8fLjAhsWUWN2pIKH_zLXcGqw).

[36] : BELHADEF Salima et BENABDALLAH Khadidja. Segmentation des images IRM cérébrales par apprentissage profond. Memoire de projet de fin d'études Pour l'obtention du Diplôme de MASTER en GENIE BIOMEDICAL Spécialité : Imagerie Médicale. Université Abou Bakr Belkaïd de Tlemcen, 22 -11- 2020.

<http://dspace.univ-tlemcen.dz/bitstream/112/16032/Ms.GBM.Belhadef%2BBenabdallah.pdf>.

[37] : OUARI Mohammed Chaker, GHRISSI Ahmed Tedjani. Classification des tumeurs cérébrale en utilisant deep learning. Mémoire de Fin D'étude Présenté pour l'obtention du Diplôme de MASTER ACADEMIQUE Domaine : Mathématique et Informatique Filière : Informatique Spécialité : Systèmes Distribués et Intelligence Artificielle Université echahid hamma lakhdar – el oued, 22-09- 2021.

<http://dspace.univ-eloued.dz/handle/123456789/9766>.

[38] : M. Durand, A. Shaikh, M. Billi, E. Lechevallier. Applications médicales de l'intelligence artificielle : opportunités & challenges, Progrès en Urologie – FMC 2020;30:F63–F68.

<https://www.urofrance.org/sites/default/files/fileadmin/documents/data/PF/2020/6420/75263/FR/1371455/main.pdf>.

[39] : MERDOUD Kenza, BOUSBAINE Karim. Détection de maladies par traitement d'image. Mémoire de fin d'étude En vue de l'obtention du diplôme de Master 02en : Filière: Informatique Option: Génie Système Informatique. Université bouira, 2017-2018.

<http://dspace.univ-bouira.dz:8080/jspui/bitstream/123456789/7155/1/D%C3%A9tection%20de%20maladies%20par%20traitement%20d%27image.pdf>.