

République Algérienne Démocratique et Populaire  
Ministère de l'enseignement Supérieur et de la Recherche Scientifique  
Université de Mohamed El Bachir El Ibrahimi de Bordj Bou Arréridj  
Faculté des Mathématiques et d'Informatique  
Département d'informatique



## **MEMOIRE**

Présenté en vue de l'obtention du diplôme  
**Master en informatique**  
Spécialité : Informatique décisionnel

## **THEME**

# **Segmentation des tumeurs cérébrales dans des images IRM par la méthode U-Net**

*Présenté par :*

NOUIRI Lahcene

DERRECHE Seddik

*Soutenu publiquement le : 20/06/2024*

*Devant le jury composé de :*

**Président :** Pr BOUZIANE Abderaouf

**Examineur :** Dr BELALTA Ramla

**Encadreur :** Dr ZOUAOUI Hakima

**2023/2024**

# Dédicace

À l'issue de ce parcours académique, je souhaite adresser une dédicace spéciale à mes proches qui ont été mes piliers tout au long de cette aventure.

À mes chers parents, dont le soutien indéfectible et les encouragements sans faille m'ont guidé à chaque étape. Votre amour inconditionnel et vos sacrifices ont été ma source de motivation la plus précieuse.

À ma Chère femme, compagnon de chaque instant, qui a partagé les hauts et les bas de cette expérience avec patience et compréhension. Ta présence à mes côtés a rendu chaque défi plus facile à surmonter.

À mes filles, mes rayons de soleil, qui ont apporté de la joie et de l'équilibre à ma vie, même dans les moments les plus stressants. Votre innocence et votre soutien m'ont donné la force de persévérer.

Cette réussite est aussi la vôtre, car chacun de vous a contribué à ma réussite d'une manière unique et irremplaçable. Je vous suis profondément reconnaissant et je vous dédie ce diplôme avec tout mon amour et ma gratitude.

NOUIRI Lahcene.

# Dédicace

À l'issue de ce parcours académique, je souhaite adresser une dédicace spéciale à mes proches qui ont été mes piliers tout au long de cette aventure.

À mes chers parents, dont le soutien indéfectible et les encouragements sans faille m'ont guidé à chaque étape. Votre amour inconditionnel et vos sacrifices ont été ma source de motivation la plus précieuse.

À ma Chère femme, compagnon de chaque instant, qui a partagé les hauts et les bas de cette expérience avec patience et compréhension. Ta présence à mes côtés a rendu chaque défi plus facile à surmonter.

À mes filles, mes rayons de soleil, qui ont apporté de la joie et de l'équilibre à ma vie, même dans les moments les plus stressants. Votre innocence et votre soutien m'ont donné la force de persévérer.

Cette réussite est aussi la vôtre, car chacun de vous a contribué à ma réussite d'une manière unique et irremplaçable. Je vous suis profondément reconnaissant et je vous dédie ce diplôme avec tout mon amour et ma gratitude.

DERRECHE Seddik.

# Remerciement

En ce moment de réussite, je tiens à exprimer ma profonde gratitude à Dieu, qui a guidé et gracieusement éclairé mon chemin à chaque étape de ce parcours éducatif. Je tiens également à exprimer ma sincère gratitude à notre enseignante, Mme Zouaoui Hakima. Sa confiance en nous et son soutien indéfectible ont été des facteurs essentiels à notre progression.

Son engagement et sa passion pour l'enseignement nous ont inspiré et encouragés à faire notre travail. meilleure Mme Zouaoui Hakima, votre dévouement à notre réussite et votre capacité à nous pousser au-delà de nos limites ont été une inspiration pour nous tous.

Nous sommes extrêmement reconnaissants pour son enseignement, sa patience et ses encouragements constants. Que Dieu vous bénisse pour vos précieuses contributions à notre éducation et à notre développement personnel.

Nous tenons également à exprimer notre profonde gratitude envers le Pr BOUZIANE Abderaouf ainsi que le Dr BELALTA Ramla pour leur soutien et leur expertise tout au long de ce parcours éducatif. Leur contribution a été inestimable dans notre réussite.

Merci beaucoup.

## • Résumé

Le traitement des images médicales, notamment celles obtenues par imagerie par résonance magnétique (IRM), est important pour avoir un diagnostiquer certaines maladies telles que les tumeurs cérébrales. Dans cette étude, nous proposons une méthode pour détecter automatiquement ces tumeurs à l'aide du réseau U-Net. Notre approche repose sur l'utilisation de cette architecture pour extraire les caractéristiques distinctives des images IRM, qui sont ensuite utilisées pour la détection des tumeurs. Les résultats montrent que notre modèle basé sur U-Net atteint une précision de détection de 95 %, démontrant son efficacité dans ce contexte. Ces résultats montrent le potentiel prometteur de l'utilisation d'U-Net pour améliorer la détection précoce et précise des tumeurs cérébrales à partir des images IRM.

• Mots clés : IRM, U-net, segmentation, Apprentissage en profondeur, Tumeurs cérébrales.

## ملخص.

تعد معالجة الصور الطبية، وخاصة تلك التي يتم الحصول عليها عن طريق التصوير بالرنين المغناطيسي (MRI)، مهمة لتشخيص بعض الأمراض مثل أورام المخ. في هذه الدراسة، نقترح طريقة للكشف التلقائي عن هذه الأورام باستخدام شبكة U-Net. يعتمد نهجنا على استخدام هذه البنية لاستخراج السمات المميزة لصور التصوير بالرنين المغناطيسي، والتي يتم استخدامها بعد ذلك للكشف عن الورم. أظهرت النتائج أن نموذجنا المستند إلى U-Net يحقق دقة اكتشاف تبلغ 95%، مما يدل على فعاليته في هذا السياق. تظهر هذه النتائج الإمكانيات الواعدة لاستخدام U-Net لتحسين الكشف المبكر والدقيق عن أورام المخ من صور التصوير بالرنين المغناطيسي.

• الكلمات المفتاحية: التصوير بالرنين المغناطيسي، U-net، التجزئة، التعلم العميق، أورام المخ.

## •Abstract

The processing of medical images, especially those obtained by magnetic resonance imaging (MRI), is important for diagnosing certain diseases such as brain tumors. In this study, we propose a method to automatically detect these tumors using the U-Net network. Our approach is based on using this architecture to extract distinctive features from MRI images, which are then used for tumor detection. The results show that our U-Net-based model achieves a detection accuracy of 95%, demonstrating its effectiveness in this context. These results show the promising potential of using U-Net to improve the early and accurate detection of brain tumors from MRI images.

• Keywords: MRI, U-net, segmentation, Deep learning, Brain tumors.

# Table des matières

<b>Table des figures .....</b>	<b>VIII</b>
<b>Introduction générale.....</b>	<b>1</b>
<b>1 Concept médicaux techniques .....</b>	<b>3</b>
1.1 Introduction .....	3
1.2 Description du cerveau .....	4
1.2.1 Description externe du cerveau .....	4
1.2.2 Description interne du cerveau.....	4
1.3 Anatomie cérébrale .....	4
1.3.1 Le cerveau .....	4
1.3.2 Cervelet .....	5
1.3.3 Tronc cérébrale .....	6
1.4 Les tissus du cerveau.....	7
1.4.1 Matière blanche (la substance blanche) .....	7
1.4.2 Matière grise (la substance grise) .....	7
1.4.3 La matière céphalo-rachidien (LCR) (ou liquide cébrospinal, LC.....	8
1.5 Exploration Visuelle du Cerveau .....	8
1.5.1 Le cycle vasculaire cérébral.....	9
1.5.2 Cellules cérébrales .....	9
1.6 Tumeur Cérébrale .....	10
1.6.1 Tumeur cérébrale bénignes .....	10
1.6.2 Tumeurs malignes .....	11
1.6.3 Types de tumeurs cérébrales .....	11
1.6.4 Causes des tumeurs cérébrales.....	12
1.6.5 Diagnostic des tumeurs cérébrales .....	12
1.7 L'imagerie Médicale .....	13
1.7.1 Imagerie par résonance magnétique IRM.....	14
1.8 Principe de l'IRM.....	15
1.8.1 Pondération et séquence des images IRM.....	15
1.8.2 Image pondérée par la densité de protons ( $\rho$ ).....	16
1.8.3 Images pondérées T2.....	16
1.8.4 Images pondérées T1.....	16
1.9 Conclusion.....	17
<b>2 Apprentissage Profonde .....</b>	<b>18</b>
2.1 Introduction .....	18
2.2 Intelligence artificielle (intelligence artificielle).....	19
2.3 Apprentissage automatique .....	19



2.4	<i>Apprentissage profond</i> .....	20
2.4.1	Définition.....	20
2.4.2	Historique de l'apprentissage profond :.....	20
2.4.3	Pourquoi l'apprentissage profond ?.....	21
2.5	<i>Exemples d'application</i> .....	22
2.6	<i>Défis</i> .....	23
2.7	<i>Conclusions</i> .....	23
<b>3</b>	<b>Les méthodes de détection de la tumeur</b> .....	<b>24</b>
3.1	<i>Introduction</i> .....	24
3.2	<i>Segmentation</i> .....	24
3.1	<i>Méthodes Segmentation</i> .....	24
3.1.1	La segmentation manuelle.....	24
3.1.2	La segmentation semi-automatique des IRM cérébrales.....	24
3.1.3	La segmentation automatique des IRM cérébrales .....	25
3.2	<i>Travaux connexes</i> .....	25
3.3	<i>Difficultés liées à la segmentation des images cérébrales</i> .....	27
3.4	<i>Conclusion</i> .....	27
<b>4</b>	<b>Contribution et résultat</b> .....	<b>28</b>
4.1	<i>Introduction</i> .....	28
4.2	<i>Méthode proposée</i> .....	28
4.2.1	Ensemble de données IRM.....	29
4.2.2	Ensembles de données d'entraînement, de test et de validation .....	29
4.2.3	Prétraitement des données.....	30
4.3	<i>Architecture U-net</i> .....	34
4.3.1	Réseau U-net de base .....	34
4.3.2	Avantages du U-Net : .....	38
4.4	<i>Le modèle proposé</i> .....	39
4.4.1	Créer un modèle     U-Net : Réseaux de convolution pour la segmentation d'images biomédicales 39	
4.5	<i>Environnement d'implémentation</i> .....	40
4.6	<i>Logiciel</i> .....	40
4.7	<i>La phase d'évaluation</i> .....	41
4.8	<i>Analyse des Résultats et Échanges</i> .....	43
4.9	<i>La prédiction</i> .....	44
4.9.1	Le fonctionnement de l'application .....	44
4.10	<i>Conclusion</i> .....	45
	<b>Conclusion générale</b> .....	<b>46</b>

## Table des figures

---

1.1: L'emplacement du cervelet	05
1.2: Tronc cérébrale	06
1-3 : Montre une section axe du cerveau	07
1.4: Les tissus du cerveau	08
1.5: Les axes de coupe pour la visualisation de cerveau	09
1.6: Les différentes cellules du cerveau	10
1.7: L'imagerie par résonance magnétique IRM	14
1.8 Différentes modalités d'images cérébrales IRM	16
2.1: La relation entre AI, ML et DL	19
2.2: Comment l'apprentissage profond fonctionne	20
4.1: L'ensemble de données IRM	29
4.2: Outil de recadrage des images RM	31
4.3: Dataset après le recharge	32
4.4: Afficher chaque tranche des données NIFTI 3D	32
4.5 : Les images IRM redimensionnées	33
4.6: Technique d'augmentation sur l'image originale	34
4.7. Architecture de base du réseau U-Net	35
4.8. Architecture 3D-Unet	37
4.9. Architecture V-Unet	37

# Introduction générale

---

L'utilisation de l'architecture U-Net pour la détection des tumeurs cérébrales à partir d'images IRM représente un progrès majeur dans le domaine de la médecine. Les tumeurs cérébrales sont des affections graves nécessitant une détection précoce et précise pour un traitement efficace. Traditionnellement, l'interprétation des images IRM pour détecter ces tumeurs basées sur l'expertise des radiologues et des pathologistes, ce qui pouvait être sujet à des erreurs et des variations.

Cependant, grâce aux progrès de l'intelligence artificielle et en particulier de l'architecture U-Net, il est possible d'entraîner des modèles informatiques à reconnaître automatiquement les caractéristiques des tumeurs cérébrales dans les images IRM. L'objectif de ce travail est la détection des tumeurs cérébrales dans des images IRM par l'architecture U-Net. L'utilisation de cette technique vise à développer des modèles d'intelligence artificielle capables d'analyser les images d'IRM du cerveau et de détecter avec précision la présence de tumeurs. Le but principal est de fournir des méthodes de diagnostic précoce des tumeurs cérébrales et de faciliter le processus de détection.

Cette approche est basée essentiellement sur l'entraînement de modèles informatiques basé sur de grande base de données d'images cérébrales, qui permettant d'extraire les caractéristiques et les motifs distinctifs des tumeurs cérébrales et de les distinguer des tissus sains. En utilisant l'architecture U-Net, la capacité des systèmes informatiques à reconnaître les tumeurs cérébrales est améliorée, ce qui contribue à augmenter les chances de traitement précoce et à améliorer les résultats des soins de santé pour les patients.

Notre travail consiste à mettre en place un modèle qui permet la détection des tumeurs cérébrales à partir des images IRM, pour la détection précoce du cancer et pour faciliter au maximum le processus de détection. Ce travail est divisé en quatre chapitres qui nous permettront de présenter les différents aspects de notre travail. Cela a été réalisé en suivant les étapes détaillées dans les chapitres suivants :

Chapitre 1 : Concept médicaux techniques

Dans cette partie nous avons défini les aspects liés à la tumeur cérébrale et concept des images IRM.

### Chapitre 2 : Apprentissage Profonde

Dans cette partie nous avons abordé la définition de l'apprentissage profond et leur historique et quelque domaine d'utilisation quotidien.

### Chapitre 3 : Les méthodes de détection de la tumeur

Dans ce chapitre nous avons essayé, de mettre en place la notion de détection et segmentation. Ainsi en se basant sur quelques méthodes les plus connus.

### Chapitre 4 : Contribution et Résultats.

Dernière partie nous éprouvons des données une description pour l'approche proposée ainsi que ces résultats obtenus.

Ce travail se termine par une conclusion générale.

**Problématique** : la segmentation des tumeurs cérébrales pose un problème difficile et complexe qui fait le lancement d'un sujet de recherche très nouveau dans le domaine médical. Les difficultés de segmenter des images IRM pour détecter une tumeur cérébrale sont tout jour complexe. L'objectif de ce travail a réalisé un modèle capable d'apprendre et être capable de segmenter les structures cérébrales à partir d'images IRM, selon deux méthodes différentes : utiliser méthode d'optimisation métaheuristique OEP pour diviser les tissus cérébraux en trois couches (MB, MG, CSF) et détecter les tumeurs.

# 1 Concept médicaux techniques

---

## 1.1 Introduction

Récemment, la tumeur s'est propagé, en particulier la tumeur du cerveau, la dernière en date étant les tumeurs les plus graves et le patient peut ressentir un certain nombre de symptômes dans le corps en fonction de la localisation de la tumeur dans le cerveau.

Ces tumeurs sont des amas de cellules caractérisées par une division incontrôlée et nous pouvons classer les tumeurs cérébrales en deux types selon leur nature, leur origine et leur taux de croissance. La détection précoce du cancer peut donner à une personne une nouvelle chance dans la vie, pour suivre un traitement efficace pour le sauver.

L'exploration cérébrale par imagerie par résonance magnétique (IRM) est un moyen rapide de détecter les tumeurs. L'imagerie par résonance magnétique (IRM) est une méthode largement utilisée pour produire des images médicales de haute qualité. Cependant, les techniques de détection du cancer doivent être fiables et robustes pour le diagnostic. C'est dont nous parlerons dans ce chapitre.

## 1.2 Description du cerveau

### 1.2.1 Description externe du cerveau

Le cerveau est le centre de commande principal du corps, situé en haut de la colonne vertébrale, qui est constitué d'un réseau de neurones s'étendant du cou à la colonne vertébrale inférieure. Il reçoit des signaux des organes pour détecter les sensations internes et externes, analyse rapidement ces informations et envoie des messages appropriés pour réguler les mouvements et les fonctions corporelles. Le cerveau stocke également des souvenirs, favorise l'apprentissage et la mémoire, et est une source d'idées, d'émotions et de pensées [1].

### 1.2.2 Description interne du cerveau

Au niveau microscopique, le tissu nerveux est composé de cellules nerveuses appelées neurones et de cellules de soutien et de protection appelées cellules gliales, qui dérivent toutes deux de l'ectoderme. Les vaisseaux sanguins et les méninges, qui ne font pas partie du tissu nerveux, sont dérivés du mésoderme. Les neurones constituent l'unité fonctionnelle de base du système nerveux et sont environ 10 à 50 fois plus nombreux que les cellules gliales. On estime qu'il y a environ 100 milliards de neurones dans le système nerveux humain. Les neurones sont responsables de la transmission d'un signal électrique appelé influx nerveux [2].

## 1.3 Anatomie cérébrale

### 1.3.1 Le cerveau

Le cerveau est la partie prédominante du système nerveux central, représentant environ 85% de son poids et pesant entre 1300 et 1500 grammes. Situé dans la partie supérieure du crâne, il est responsable de la régulation des mouvements musculaires, de la production d'hormones, du développement des émotions et des sentiments, ainsi que de la mémorisation, de la préservation et de l'apprentissage. Le cerveau est constitué de deux hémisphères cérébraux séparés par une fissure centrale et abrite les principaux lobes cérébraux majeurs, chacun ayant de multiples fonctions [3].

Les lobes	Principale fonction
<b>Lobe frontal</b>	<ul style="list-style-type: none"> <li>• Langage et parole</li> <li>• Contrôle de mouvement</li> <li>• Comparaison et classification</li> <li>• Formation du personnage</li> <li>• Gérer l'attention</li> </ul>
<b>Lobe pariétal</b>	<ul style="list-style-type: none"> <li>• Lecture, perception visuelle.</li> <li>• La sensation de toucher, de douleur et de température.</li> <li>• Le lobe pariétal droit gère la sensibilité du côté gauche de Corps.</li> <li>• Le lobe pariétal gauche gère la sensibilité du côté droit De Corps.</li> </ul>
<b>Lobe occipital</b>	<ul style="list-style-type: none"> <li>• Gestion de la visibilité spatiale, prise de conscience de l'distance, de la profondeur et de la couleur.</li> </ul>
<b>Lobe temporal</b>	<ul style="list-style-type: none"> <li>• Comprendre la langue et les émotions.</li> <li>• Séquence et organisation</li> </ul>

Table 1.1: Les types de lobes et leurs fonctions [4]

### 1.3.2 Cervelet

Le cervelet se situe dans la partie supérieure du tronc cérébral, à l'endroit où la moelle épinière se connecte au cerveau. Il représente environ 10% du poids total du cerveau, mais compte pour environ la moitié du nombre total de neurones présents dans le cerveau. Ces neurones sont responsables de la transmission de signaux électriques du corps vers le cerveau. Le rôle principal du cervelet est de recevoir des informations provenant des organes sensoriels, de la moelle épinière et d'autres parties du cerveau, et de réguler les mouvements volontaires [5].




Figure 1.1: L'emplacement du cervelet. [6]

### 1.3.3 Tronc cérébrale

Le tronc cérébral est une partie essentielle du système nerveux qui assure des fonctions vitales pour la vie humaine. Il s'agit du centre de passage des neurones sensoriels et moteurs émis et contenus dans le cerveau. L'une de ses fonctions les plus importantes est de réguler l'équilibre corporel, la température corporelle, la fréquence respiratoire et la pression artérielle. Le tronc cérébral est constitué de trois structures majeures qui travaillent en synergie pour maintenir ces fonctions vitales [7] :

#### ➤ **Mésencéphale**

Le cerveau intermédiaire est un centre important pour le mouvement oculaire et le traitement de l'information audiovisuelle [7].

#### ➤ **Le Pont**

Le pont est un groupe de nerfs qui connecte les parties du cerveau. La majeure partie du tronc cérébral est constituée de neurones circadiens, responsables de la transmission d'informations sensorielles et de la participation aux mouvements du visage [7].

#### ➤ **Bule rachidien**

Contrôle la respiration, la tension artérielle, les rythmes cardiaques et la déglutition, où les messages du cortex sont envoyés à la moelle épinière et aux nerfs qui se ramifient de la moelle épinière à travers le pont et le tronc cérébral [7].

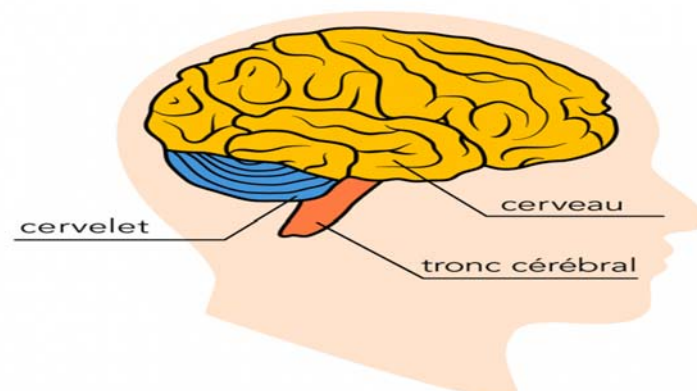


Figure 1.2: Tronc cérébrale. [8]



## 1.4 Les tissus du cerveau


### 1.4.1 Matière blanche (la substance blanche)

La substance blanche est un type de tissu du système nerveux central, principalement composé d'axones myélinisés de neurones. Il constitue la partie interne du cerveau et la partie externe de la moelle épinière. La substance blanche contient des axones qui sont des extensions des neurones. Ces extensions sont entourées de gaines et de cellules de myéline à une nature non-neuronale et participent à la structure du tissu interstitiel des cellules nerveuses : les nerfs gliaux. Le rôle de la substance blanche est d'assurer la transmission de l'influx nerveux [9].

### 1.4.2 Matière grise (la substance grise)

Composé principalement de corps cellulaire et d'arbre dendritique neurones ainsi que certaines cellules gliales. Il semble plus sombre que le reste du tissu, car il contient le noyau cellulaire. Nous avons trouvé, la matière grise se situe principalement au niveau du cortex cérébral, de l'insula, des noyaux gris centraux et des noyaux du tronc cérébral. Et à l'intérieur de la moelle épinière.

- **Cortex cérébral** : couvre l'ensemble du cerveau. Sa superficie est grande, car il suit toutes les spirales externes du cerveau.
- **Noyaux basaux** : avec le cortex cérébral, sont les seules structures de La matière grise du cerveau est également constituée de cellules neurones, mais à une densité plus faible que dans le cortex cérébral. Ils comprennent les noyaux du télencéphale, ces noyaux sont appelés noyau basal (ou striatum), parmi lequel on distingue le noyau accumbens noyau caudé et noyau lenticulaire.



La figure 1-3 : montre une section axe du cerveau. [09]

### 1.4.3 La matière céphalo-rachidien (LCR) (ou liquide céphalospinal, LC

Le liquide céphalo-rachidien est une substance claire composée de 99% de l'eau est contenue dans le système nerveux central, dans deux zones les caractéristiques anatomiques sont très différentes. Liquide céphalo-rachidien ou liquide céphalo-rachidien entoure le cerveau et remplit les ventricules cérébraux. Cela aide à protéger Le cerveau provoque un choc en agissant comme un amortisseur et en remplissant des fonctions importantes dans les échanges entre le sang et les tissus nerveux.




Figure 1.4: Les tissus du cerveau. [10]

## 1.5 Exploration Visuelle du Cerveau

Des observations utilisant des sections bidimensionnelles du cerveau peuvent être suivies de nombreux points de vue. Ainsi, les gens distinguent 3 axes anatomiques pour réaliser des coupes [11] :

- **Coupes axiales** : les coupes axiales sont des coupes d'imagerie médicale Pratiquement dans un plan horizontal du corps. En IRM, ces coupes sont perpendiculaires à l'axe du champ magnétique principal.
- **Coupe sagittale** : La coupe sagittale est une image obtenue par découpe Cerveau ou toute autre structure anatomique dans un plan vertical, parallèle à Ligne médiane du corps. Ils nous permettent de visualiser les structures latérales du cerveau et fournit une vue générale de la zone d'intérêt.
- **Coupes circulaires** : Ce sont des coupes perpendiculaires aux coupes axiales et sagittales, elles correspondent à l'image frontale du cerveau.

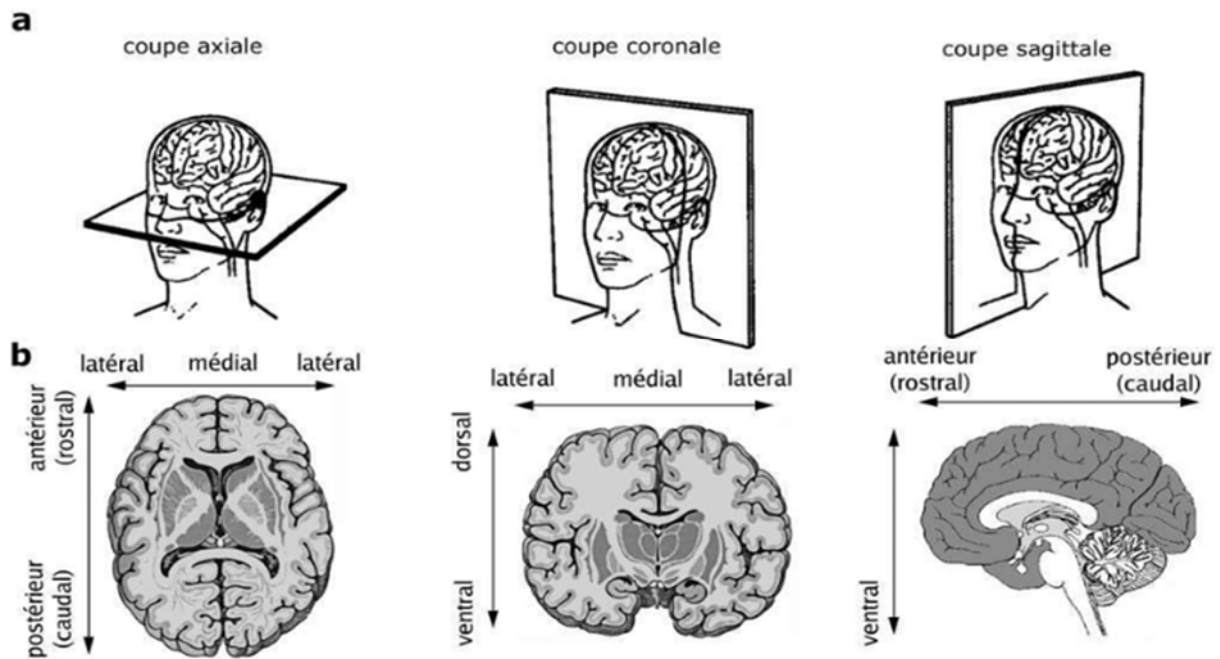


Figure 1.5: Les axes de coupe pour la visualisation de cerveau. [12]

### 1.5.1 Le cycle vasculaire cérébral

Le cycle vasculaire cérébral correspond à la circulation sanguine qui alimente le cerveau à travers un réseau de vaisseaux sanguins. Les artères transportent le sang oxygéné et les nutriments vers le cerveau, tandis que les veines évacuent le sang désoxygéné et les déchets métaboliques. Le système vasculaire cérébral dispose de plusieurs mécanismes préventifs pour garantir une irrigation sanguine suffisante au cerveau, qui est très vulnérable à une pénurie de sang [13]

### 1.5.2 Cellules cérébrales

Les cellules du cerveau, ou neurones, sont des cellules qui ont un corps cellulaire avec des extensions nerveuses appelées dendrites et un cylindre d'axe appelé axone, qui se termine par des plaques terminales où les synapses peuvent se former. Les synapses sont plus importantes que le nombre de cellules nerveuses dans l'échange d'informations entre les cellules du cerveau, car elles transportent des informations même dans des zones éloignées du corps. Les dendrites peuvent atteindre jusqu'à un mètre de long et une cellule du cerveau peut contenir jusqu'à 10000 dendrites [14].

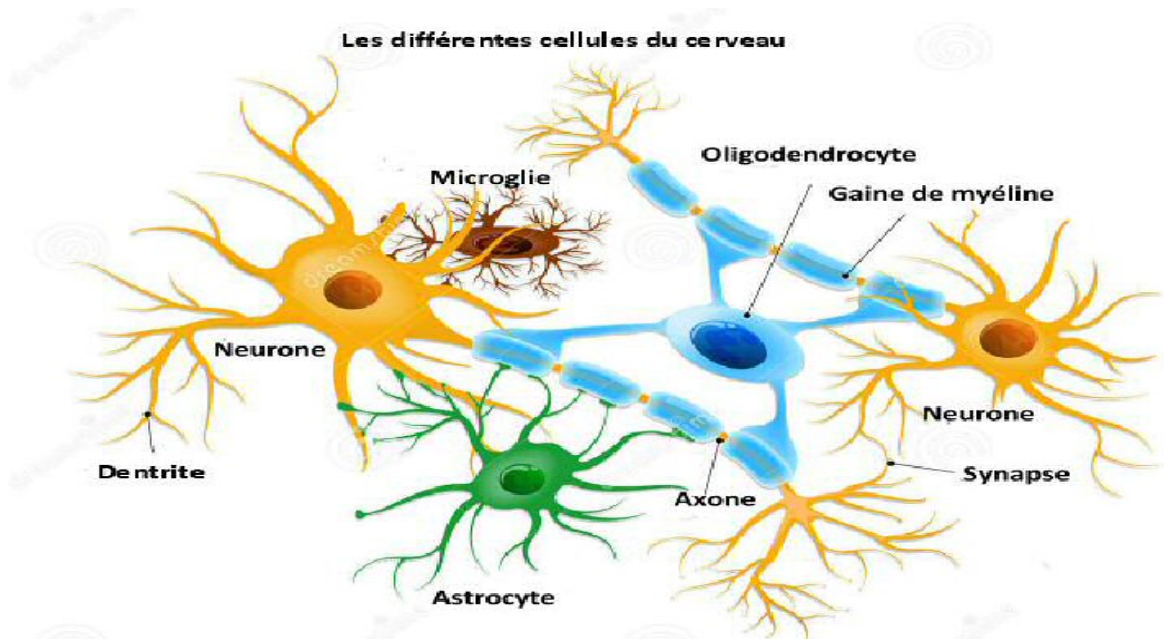


Figure 1.6: Les différentes cellules du cerveau [14]

## 1.6 Tumeur Cérébrale

Une tumeur est une masse de cellules anormales qui se multiplie de manière incontrôlée, créant une croissance anormale. Ces cellules anormales continuent de se diviser et de croître, d'envahir les tissus voisins et éventuellement de se propager à d'autres parties du corps. Les tumeurs peuvent être bénignes (non cancéreuses) ou malignes (cancer cérébraux), selon leur capacité à se propager et à envahir les tissus voisins. Les tumeurs malignes peuvent causer des dommages importants aux tissus environnants et peuvent être mortelles si elles ne sont pas traitées.

### 1.6.1 Tumeur cérébrale bénignes

Ces tumeurs ne contiennent pas de cellules cancéreuses, elles sont constituées des cellules se développent lentement et n'envahissent pas les tissus environnants. Une tumeur cérébrale bénigne peut être surveillée simplement par des méthodes radiologiques, ou complètement retiré chirurgicalement ou distance partielle. Si la tumeur bénigne n'est pas complètement éliminée peut récidiver [15].

### 1.6.2 Tumeurs malignes

Les tumeurs malignes sont des masses de cellules cancéreuses capables de se développer et se développent de manière incontrôlable, envahit les tissus environnants et se propage vers d'autres parties du corps par le système sanguin ou lymphatique. Ce processus de propagation est appelé métastase. Contrairement aux tumeurs bénignes, Les tumeurs malignes sont considérées comme un risque pour la santé en raison de leur potentiel de se propager rapidement à d'autres parties du corps [15].

### 1.6.3 Types de tumeurs cérébrales

- **Les tumeurs primitives** : les tumeurs primaires du cerveau sont des croissances anormales de cellules qui peuvent être bénignes ou malignes et causer des symptômes graves, en particulier lorsqu'elles se trouvent dans des zones clés du cerveau [16].
- **Les tumeurs secondaires** : les tumeurs secondaires sont des cancers qui se développent à partir de cellules cancéreuses qui se sont propagées depuis une tumeur initiale située en dehors du cerveau, par le biais de la circulation sanguine, vers le tissu cérébral.

Exemples des tumeurs cérébrales primitives

- **Gliome**

Les tumeurs cérébrales se développent à partir des structures de soutien du cerveau système nerveux et cellules gliales. Il existe de nombreux types de cellules Les cellules gliales sont responsables du développement de certains types de gliomes. La plupart des tumeurs cérébrales sont des gliomes.

- **Méningiomes**

La plupart des tumeurs bénignes se développent de manière dommageable des méninges, à l'intérieur du crâne ou le long de la colonne vertébrale. La majorité des méningiomes sont bénins, mais dans certains cas isolés, certains à noter que l'évolution est défavorable (bénigne à maligne).

- **Névrome**

La plupart des tumeurs sont bénignes (grade I dans la majorité des cas) se développent à partir des gaines des nerfs périphériques (appelées cellules par Schwann). Ces tumeurs se trouvent

dans les nerfs crâniens et les nerfs périphérie de tout le corps. La tumeur la plus courante est le schwannome ou névrome.

#### ➤ Adénome

Hypophysaire L'adénome hypophysaire est une tumeur bénigne. Cette tumeur peut créer des troubles hormonaux ou parfois des problèmes de vision, ceux-ci Les symptômes sont dus à la pression de la tumeur sur la zone du cerveau.

#### ➤ Médulloblastome

Les tumeurs malignes situées dans le cervelet touchent les enfants surtout les moins de 15 ans.

#### ➤ Lymphome

Le lymphome est une tumeur qui affecte le système lymphatique. Le lymphome primitif du système nerveux central est une tumeur maligne rare qui survient Les lymphomes secondaires du système nerveux central se présentent souvent sous forme sur l'invasion du cortex cérébral.

#### ➤ Métastase

Les tumeurs sont formées à partir de cellules cancéreuses qui éclatent à partir d'une tumeur première tumeur. Parfois, ces tumeurs secondaires sont le premier signe d'une maladie. Les métastases sont malignes et secondaires à une tumeur d'autres zones du corps (poumons, seins, peau, etc.). Les cellules cancéreuses bougent au cerveau par le sang.

### 1.6.4 Causes des tumeurs cérébrales

De nombreuses études scientifiques ont été menées où sont actuellement en cours pour déterminer les facteurs qui favorisent l'apparition d'une tumeur cérébrale. Nous parlons de facteurs de risque. Trois types de facteurs de risque sont étudiés : les risques liés à l'environnement, l'hérédité et les 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 [17].

### 1.6.5 Diagnostic des tumeurs cérébrales

#### 1.6.5.1 Examen clinique

Lorsqu'un médecin soupçonne la présence d'une tumeur cérébrale, il effectue en premier lieu un examen clinique approfondi afin de localiser la zone cérébrale affectée. Étant donné que

chaque région du cerveau est associée à des fonctions spécifiques du corps, la détection de symptômes périphériques peut aider à identifier la zone du cerveau touchée [18].

### 1.6.5.2 Examen des images

Les examens d'imagerie sont des techniques utilisées pour produire des images précises du cerveau, afin de détecter la présence d'une tumeur, de la localiser avec précision, de mesurer sa taille et d'évaluer son impact sur le cerveau. L'IRM (imagerie par résonance magnétique) est l'examen de choix pour le diagnostic des tumeurs cérébrales, mais il est parfois précédé d'un scanner pour des raisons pratiques.

#### ➤ Un scanner

Le scanner est une technique d'imagerie médicale qui utilise des rayons X pour produire des images en coupes transversales du corps. Ces images sont ensuite traitées par un ordinateur pour créer une représentation en trois dimensions de la zone examinée [19].

#### ➤ Imagerie par résonance magnétique (IRM)

L'IRM est une technique d'imagerie médicale qui utilise des champs magnétiques et des ondes radio pour créer des images détaillées du corps, y compris du cerveau. Elle n'utilise pas de rayonnements ionisants. L'IRM permet la visualisation précise des tissus mous du cerveau et peut détecter des lésions, des tumeurs ou des maladies dégénératives. De plus, elle peut guider les interventions chirurgicales cérébrales [20].

## 1.7 L'imagerie Médicale

L'imagerie médicale est certainement l'un des domaines de la médecine qui a vécu le plus progressé ces vingt dernières années, c'est une méthode pour concevoir une carte de caractéristiques [24] spécifiques du corps humain à utiliser pour établir un diagnostic ou un traitement médical.

L'imagerie médicale regroupe toutes les techniques qui le permettent visualiser une partie du corps humain ou un organe sans avoir à opérer le patient ; cela, une image visuelle compréhensible d'une information à caractère médical dans le but d'établir un diagnostic et de faire un suivi approprié du traitement. Il existe plusieurs modalités d'imagerie médicale tel que la tomodensitométrie X (TDM), échographie, tomographie par émission de positons (TEP ou PET) et Imagerie par Résonance Magnétique (IRM). Dans la mémoire, nous nous intéressons à l'IRM



### 1.7.1 Imagerie par résonance magnétique IRM

L'imagerie par résonance magnétique (IRM) est une technique d'imagerie médicale, utilisée à des fins de diagnostic et repose sur les principes de Résonance Magnétique Nucléaire (RMN). Cela facilite donc la production images anatomique dans plusieurs plans et peuvent fournir des informations sur la composition des tissus. Cette méthode de photographie est devenue un outil de plus en plus important en médecine ou dans la recherche sur le cerveau en neurosciences cognitives. Les appareils IRM utilisent des champs magnétiques et des ondes radio pour créer des images de différentes parties du corps que nous ne pouvons pas voir par radiographie, tomodensitométrie et échographie. Les composantes principales de IRM

Les scanners IRM ont considérablement évolué depuis les années 1980.

Un imageur est essentiellement composé de cinq éléments de base :

- L'aimant.
- Les génératrices d'onde radiofréquence (RF).
- Les récepteurs d'ondes.
- Les bobines de gradient.
- L'unité de traitement.



Figure 1.7 – l'imagerie par résonance magnétique IRM [25]



L'aimant est le composant le plus cher d'un imageur à résonance magnétique, cela crée un champ  $B_0$ . Les bobines de dégradé créent un dégradé de champ  $B_0$  dans les directions X, Y et Z. La bobine RF génère un champ magnétique  $B_1$  est nécessaire pour faire tourner les spins de  $90^\circ$  à  $180^\circ$ . La bobine RF détecte également les signaux provenant des rotations du corps humain. le patient est placé à l'intérieur de l'aimant où un ordinateur contrôle la table du patient. La clinique est entourée de matériaux de protection.

## 1.8 Principe de l'IRM

L'IRM s'appuie sur les propriétés magnétiques des atomes qu'elle constitue les molécules du corps humain. Il se concentre plus précisément sur les molécules L'hydrogène ce présent dans l'eau représente plus de 70 % de notre corps. Le noyau d'hydrogène se comporte comme une charge électrique qui tourne son axe : c'est un mouvement de rotation. Les protons peuvent alors être comparés dipôle magnétique. En l'absence de champ magnétique, s'orienter dans l'espace au hasard. Ce mouvement donne au noyau.

Un moment cinétique dépend de sa masse et un moment magnétique dépend de sa charge. Dans le champ magnétique  $B_0$ , les protons sont alors orientés par rapport à  $B_0$  et décrivent un mouvement de précession autour de ce champ (de la forme cône), a une vitesse angulaire constante. Tous les protons sont orientés en conséquence. La direction de  $B_0$  forme alors une sous-population à rotation  $+1/2$  ; tous orientés dans la direction opposée formant un ensemble spin  $-1/2$ . Supplémentaire La population de spin  $+1/2$  est la plus grande, il y a donc magnétisation Le  $M_0$  obtenue est proportionnel au nombre de protons présents.  $M_0$  n'est pas disponible que la composante verticale, dans la direction  $B_0$ .

### 1.8.1 Pondération et séquence des images IRM

Les paramètres de séquence sont des paramètres que l'opérateur définit sur le panneau de commande pour déterminer la séquence IRM. Ils permettent de contrôler l'influence de différents paramètres tissulaires et ainsi d'ajuster le contraste sur la photo. En modifiant les paramètres d'acquisition, notamment le temps de répétition entre deux stimulations (TR) ou le temps entre les signaux de stimulation et capture d'écho (Echo Time, TE) [25]. Le choix de tous 7 Les paramètrént dépendent alors de l'étude clinique réalisée. Nous pouvons avoir Images pondérées T1, T2, densité de protons  $\rho$ , etc.

### 1.8.2 Image pondérée par la densité de protons ( $\rho$ )

Pour les TR longs (environ 2 secondes) et les TE court (environ 20 millisecondes), Différence de densité de protons entre la matière grise et la matière blanche s'exprimer. Nous obtenons des séquences qui reflètent la position et la concentration de noyaux d'hydrogène de différentes structures. Nous en obtenons une série de densités de protons  $\rho$ , reflète la position et Concentration nucléaire d'hydrogène de différentes structures. Tissu classé selon des niveaux croissants de matière grise dans la substance blanche (MB), la matière grise (MG) et le liquide céphalo-rachidien (LCR).

### 1.8.3 Images pondérées T2

Pour les TR longs (environ 2 secondes) et les TE longe (environ 90 millisecondes) moins « agréable à l'œil » mais contient plus d'informations sur ses ingrédients tissus (principalement la teneur en eau), l'atténuation du signal prévaut sur différences de densité de protons entre les tissus. Le signal est alors suffisant pour créer des images appelées images pondérées T2, dans lesquelles les tissus sont disposés dans l'ordre augmentation des niveaux de gris dans MB, MG, LCR.

### 1.8.4 Images pondérées T1

Pour des RT de 600 ms, le contraste tissulaire dépendait est essentiellement leur taux de magnétisation, donc T1. Pour des TE d'environ 20 ms, la différence d'atténuation du signal entre les tissus ne change pas. Il n'y a pas de temps pour s'exprimer, rendant le contraste indépendant de T2. Donc, nous avons obtenu des images pondérées T1, dans lesquelles les tissus ont été triés par grade La matière grise augmente progressivement dans le liquide céphalo-rachidien, puis la matière grise blanche




Figure 1.8 Différentes modalités d'images cérébrales IRM [26]

- a) pondération T1

- (b) pondération T2
- (c) pondération en densité de protons [27]

## 1.9 Conclusion

Dans ce chapitre, nous avons abordé les différents aspects de la médecine et de la neuroscience, notamment les concepts scientifiques liés au cerveau et la manière dont la tumeur cérébrale sera diagnostiquée en utilisant l'IRM. Dans le chapitre suivant, nous essayons de discuter sur les aspects techniques cruciaux pour l'analyse des images IRM : l'apprentissage profond. C'est une méthode sophistiquée permet d'extraire des informations précieuses à partir des images IRM, ce qui peut aider les professionnels de la santé à faire des diagnostics fiables et à traiter les maladies du cerveau de manière plus efficace. En utilisant le potentiel de l'apprentissage profond, pour mieux comprendre comment cette technologie peut contribuer à l'amélioration des soins de santé dans le domaine des neurosciences.

## 2 Apprentissage Profonde

---

### 2.1 Introduction

Avec les progrès récents dans le domaine de l'apprentissage profond en vision par ordinateur au cours de la dernière décennie, l'apprentissage est de plus en plus utilisé dans l'analyse d'images médicales. En utilisant la profondeur de L'apprentissage de la vision par ordinateur a connu une croissance rapide dans de nombreux domaines différents, mais il reste encore confronté à un certain nombre de défis. Défis dans le domaine de l'imagerie médicale. De nombreuses techniques révolutionnaires ont été développées au fil des années pour surmonter ces différents défis. De nombreuses techniques et méthodes ont été améliorées pour évoluer pour faire face à de tels défis. Une de ces techniques qui sera discutée dans cette revue serait U-net, une technique d'apprentissage profond largement adoptée dans la communauté de l'imagerie médicale. U-net est une architecture de réseau neuronal principalement conçue pour la segmentation d'images [27]. Les trucs de base la structurent de l'architecture, U-net se compose de deux chemins. Le premier chemin est aussi le chemin de contraction appelé encodeur ou chemin de balayage, similaire à un réseau convolutive conventionnel et fournit des informations de classification. Le second est le chemin d'expansion, également connu sous le nom de décodeur ou voies synthétiques, y compris des combinaisons et des jointures incrémentielles avec les caractéristiques de chemin de contraction. Cette extension permet au réseau d'apprendre les informations de classification locales. De plus, le chemin étendu augmente également la résolution de la sortie qui peut ensuite être transmise. Sur la dernière couche convolutive pour créer une image entièrement segmentée. Le réseau résultant est presque la symétrie, lui donnant une forme de U-net. La tâche classique principale est effectuée par la plupart des convolutions, le réseau consiste à classer l'image entière en une seule étiquette. Toutefois, le réseau de classification ne fournit pas des informations contextuelles au niveau des pixels essentiels à l'analyse des images médicales. Alors qu'il y a eu des tentatives antérieures de segmentation des tâches, mais il a fallu attendre U-net de Ronneberger et al. [28] qu'il y a une amélioration significative des performances de segmentation des images médicales. Le réseau U-net a été développé sur la base des travaux de Long, J et al. Utilise la

convolution complet réseau. Leur implémentation offre de meilleures performances que les meilleures performances précédentes sur ISBI. 2012 et a remporté l'ISBI Cell Tracking Challenge 2015, battant Ray State à temps avec une marge importante.




Figure 2.1: La relation entre AI, ML et DL [29]

## 2.2 Intelligence artificielle (intelligence artificielle)

L'intelligence artificielle (IA) est une technologie qui permet aux machines de simuler l'intelligence humaine utilisant des outils tels que le big data, le cloud computing, réseaux de neurones artificiels et apprentissage automatique. La machine est équipée d'IA peut percevoir, reconnaître, apprendre, réagir et résoudre des problèmes, permettant d'interagir avec les humains et de les aider à atteindre des niveaux performances supérieures. L'IA est considérée comme la prochaine innovation disruptive révolutionnera le lieu de travail du futur [30] [31].

## 2.3 Apprentissage automatique

L'apprentissage automatique est une méthode de recherche qui permet aux ordinateurs d'apprendre à partir de données sans être explicitement programmés. Cette technique est utilisée pour apprendre aux machines à gérer les données plus efficacement, notamment dans les cas où les informations extraites sont difficiles à évaluer manuellement. Avec la croissance exponentielle des ensembles de données disponibles, l'utilisation L'apprentissage automatique est de plus en plus utilisé dans de nombreux secteurs pour extraire des informations importantes [32].

## 2.4 Apprentissage profond

### 2.4.1 Définition

Deep Learning, également appelé Deep Learning en anglais, est une technique L'intelligence artificielle comprend la création de réseaux de neurones artificiels, fonctionne de manière similaire au cerveau humain, avec des couches successives traitement de l'information. Ce processus permet aux machines d'extraire des fonctionnalités de données non structurées ou non étiquetées et de les utiliser pour effectuer des tâches complexes telles que la reconnaissance de formes et la classification images, traduction automatique, etc. L'apprentissage profond peut être utilisé dans de nombreux domaines tels que la reconnaissance vocale, la vision par ordinateur, l'analyse des sentiments et la prédiction de comportement [33].




Figure 2.2: Comment l'apprentissage profond fonctionne [34].

- Input layer : couche d'entrée, qui reçoit l'information et la transfère aux nœuds sous-jacents.
- Hidden layer : les couches cachées sont celles où les calculs ont lieu.
- Output layer : couche de sortie où les résultats des calculs apparaissent.

### 2.4.2 Historique de l'apprentissage profond :

Années	Contributeur	contribution
1943	<b>Warren McCulloch et Walter Pitts</b>	premier modèle mathématique et informatique du neurone biologique: le neurone formel
1957	F. Rosenblatt	Le perceptron est un neurone formel dont la fonction d'activation est une fonction échelon
1986	Yoshua Bengio Yann LeCun Geoffrey Hinton.	Les perceptrons multicouches: MLP pour objectif de classer des données plus complexe base sur des algorithmes qui s'appelle la rétropropagation du gradient de l'erreur
1990	Yann LeCun	Introduction de LeNet et démonstration de la capacité des réseaux neuronaux profonds.

1997	Hochreiter and Schmidhuber	Introduction des LSTM (Long Short-Term Memory), qui ont résolu le problème du gradient qui disparaît dans les réseaux neuronaux récurrents.
2006	Geoffrey Hinton	Introduction au Réseau de Croyance Profonde
2009	Salakhutdinov and Hinto	Introduction des Machines Boltzmann Profondes
2012	Geoffrey Hinton	Introduction d'AlexNet, vainqueur du défi ImageNet
2014	Ian Goodfellow	La naissance des Réseaux Neuronaux Génératifs Adversariaux, également connus sous le nom de GAN.
2016	Google DeepMind's	L'apprentissage par renforcement profond de Deepmind est une manière élégante de dire qu'ils utilisent un programme informatique pour apprendre à faire des choses en jouant à des jeux. Le modèle d'IA a surpassé un champion humain dans un jeu compliqué. Go est un jeu de société de stratégie.
2019	Yoshua Bengio, Geofrey Hinton, and Yann LeCun	Ils ont remporté le prix Turing en 2018 pour leur immense contribution aux progrès dans le domaine. L'apprentissage profond et l'intelligence artificielle sont deux domaines de l'informatique qui visent à créer des machines capables d'apprendre à partir de données et d'effectuer des tâches qui nécessitent normalement l'intelligence humaine.

Table 2.1: Historique de l'apprentissage profond [35] [36]

### 2.4.3 Pourquoi l'apprentissage profond ?

Les méthodes d'apprentissage automatique abordées dans la première partie ont fonctionné avec succès pour de nombreux types de questions ces dernières années, mais pas le ML. N'a pas réussi à résoudre de nombreux défis de l'IA tels que la reconnaissance vocale et la reconnaissance d'objets. En conséquence, de nombreux algorithmes d'apprentissage profond ont émergé :

- Développer des algorithmes traditionnels dans cette tâche d'IA.
- Générez de grandes quantités de données, comme le Big Data, plus il y en a données, meilleures sont les performances de l'algorithme d'apprentissage profond • Il peut s'adapter à n'importe quel défi et produire des résultats plus rapidement [37].
- Capacité à faire apprendre aux machines : les réseaux de neurones artificiels apprennent événements et prendre des décisions en commentant des événements similaires.

L'une des grandes différences entre les algorithmes de Deep Learning et les algorithmes de ML traditionnels est qu'ils sont bien évolutifs ; Plus la quantité de données fournies est importante, meilleures sont les performances de l'algorithme de

Deep Learning. Contrairement à certains algorithmes ML classiques qui ont une limite supérieure sur le nombre Les données qu'ils peuvent obtenir sont parfois appelées « plateaux de performances », des modèles du Deep Learning, de telles limitations n'existent pas (théoriquement) et elles sont même.

## 2.5 Exemples d'application

L'apprentissage profond est utilisé dans plusieurs domaines de vie tel que :

- **Reconnaissance faciale** : Les algorithmes de deep learning apprendront à détecter des images se basent sur les yeux, le nez, la bouche, etc. à partir d'une base d'images comme élément d'entrée pour un algorithme. Ensuite, grâce à l'entraînement, l'algorithme sera capable de détecter un visage sur une image. Récemment, les algorithmes de deep Learning ont obtenu des résultats prometteurs en matière de reconnaissance faciale [38].
- **Traduction automatique** : La traduction automatique existe depuis longtemps, où des phrases données dans une langue sont automatiquement traduites dans une autre langue. Mais le deep Learning fournit les meilleurs résultats dans deux domaines :
  - Traduction automatique de texte.
  - Traduction automatique d'images.

La traduction de texte peut être effectuée sans aucun traitement préalable de la séquence, permettant à l'algorithme d'apprendre les dépendances entre les mots et leur correspondance avec une nouvelle langue [38].

- **Analyse de sentiment** : L'analyse de sentiment est le processus de compréhension/analyse des sentiments des individus à travers le traitement du langage naturel, l'analyse de texte et les statistiques. Par exemple, ils ont utilisé des architectures de réseaux neuronaux sur les tweets. Cela a donné de très bons résultats.
- **Conduite Automatique** : Elles enseignent à un ordinateur à comprendre certaines parties importantes de la conduite en utilisant des systèmes de capteurs numériques à la place des humains. Pour ce faire, les entreprises commencent généralement par entraîner des algorithmes en utilisant une grande quantité de données. C'est un peu comme si les enfants apprenaient grâce à des expériences constantes et à la répétition.

### 2.5 Discussions

Le deep Learning en traitement d'images a permis diverses tâches telles que la classification, la détection, la localisation, etc. Cependant, la tâche de segmentation présente un grand intérêt pour la communauté de l'imagerie médicale. Les enquêtes menées par, ont révélé que la segmentation est la tâche classique la plus étudiée en analyse d'images médicales. Ceci est encore plus évident par la richesse de la littérature publiée spécifiquement pour les tâches de segmentation, où U-net et ses variantes continuent d'être les méthodes principales. Pour les cas d'utilisation spécifiques de l'enquête, nous avons constaté que l'IRM



était la modalité d'imagerie la plus populaire, bien qu'il existe de nombreux autres types d'imagerie sains.

## 2.6 Défis

Le succès de l'apprentissage profond est essentiel à l'amélioration du diagnostic médical. Bien qu'il y ait eu des progrès considérables dans les techniques d'apprentissage profond telles que U-net au cours de la dernière année, la nature de l'analyse médicale exige que les algorithmes exécutent avec une erreur minimale. Une limitation majeure de la réduction de cette erreur dans les techniques d'apprentissage profond est la puissance de calcul. Les puissants algorithmes d'apprentissage profond nécessitent plus de temps pour s'entraîner et sont donc moins réalisables.

Les algorithmes U-net ont appliqué l'apprentissage de transfert comme solution pour atténuer ce problème. Un autre problème crucial est la pénurie de données annotées pour la formation. Voici quelques-unes des principales raisons pour lesquelles l'apprentissage profond n'est pas encore utilisé dans n'importe quel essai médical à grande échelle dans le monde réel, malgré sa promesse énorme.

Toutefois, de jour en jour, ces problèmes deviennent plus faciles à surmonter et nous nous attendons à voir une adoption encore plus grande de l'apprentissage profond dans la communauté médicale d'imagerie.

À cet égard, nous nous attendons à ce que l'U-net soit une étape majeure dans l'apprentissage profond dans le domaine de l'analyse d'images médicales.

## 2.7 Conclusions

Dans ce chapitre, nous avons abordé et défini ce qu'est l'apprentissage profond et pourquoi nous le choisissons. Ensuite, nous avons mentionné quelques applications d'apprentissage profond dans notre vie quotidienne. Dans ce travail, nous nous concentrons sur la segmentation d'images. Alors, qu'est-ce que la segmentation d'images ? Dans le prochain chapitre, nous parlerons de la segmentation d'images et de l'état de l'art des méthodes de segmentation de tumeurs cérébrales.

## 3 Les méthodes de détection de la tumeur

---

### 3.1 Introduction

Ce chapitre présente une revue de la littérature sur les méthodes de détection, de classification et de segmentation d'images. Nous définirons la détection d'images et différentes manières types de détection tels que la détection d'objets, de contours et de fonctionnalités. Nous expliquerons également la classification et la segmentation des images, en mettant en évidence L'accent est mis sur la détection des tumeurs à partir des images IRM. En bref, cette revue livre Aperçu des connaissances actuelles et des méthodes les plus efficaces pour détecter et Tumeurs cérébrales segmentaires

### 3.2 Segmentation

La segmentation d'image constitue la base du processus d'interprétation d'image, elle demeure un sujet de recherche très en vogue en vision artificielle, de nombreuses techniques, méthodes et algorithmes peuvent être trouvés. La segmentation permet le partitionnement d'image en régions, où chaque région est constituée d'un ensemble de composantes connexes, son but est l'extraction des informations pertinentes des objets afin de permettre leurs interprétations.

### 3.1 Méthodes Segmentation

#### 3.1.1 La segmentation manuelle

La segmentation manuelle dépend du niveau de formation et d'expérience du radiologue, car elle utilise les informations multimodales présentées par les images. IRM avec différents poids (comme T1, T2 ou PD). Comme des connaissances anatomiques et physiologiques sont acquises. Cette méthode demande beaucoup de travail, implique souvent des processus tranche par tranche et est difficile à obtenir des résultats reproductibles. Obtenu même par le même opérateur. Pour un essai clinique multimodal, multi-institutionnel et longitudinal. La segmentation manuelle est largement utilisée pour évaluer les résultats. Autres méthodes telles que méthodes semi-automatiques et entièrement automatiques.

#### 3.1.2 La segmentation semi-automatique des IRM cérébrales

La segmentation semi-automatique de l'IRM cérébrale est une méthode de traitement, le traitement d'images implique l'utilisation de techniques de traitement d'images assistées par ordinateur pour faciliter la représentation des structures cérébrales dans les images IRM. Ce la méthode combine intervention humaine et automatisation pour améliorer l'efficacité et la précision de la segmentation. La segmentation semi-automatique commence généralement par

une initialisation manuelle de la segmentation, suivie d'un traitement informatique pour ajuster et affiner la segmentation. Cette technique est souvent utilisée diviser les structures cérébrales telles que le cerveau entier, le cortex cérébral, ventricules et lésions.

### 3.1.3 La segmentation automatique des IRM cérébrales

Une méthode de segmentation entièrement automatisée pour la segmentation des tumeurs cérébrales est nécessaire pour mesurer efficacement l'étendue de la tumeur. Cela ne nécessite pas d'interaction de l'utilisateur, mais combine l'intelligence artificielle et les connaissances disponibles pour résoudre le problème de segmentation. Dans cette étude, nous pouvons montrer quelques développements de cette méthode dans le cadre d'un apprentissage supervisé basé sur des réseaux de neurones artificiels.

## 3.2 Travaux connexes

De nombreux chercheurs ont contribué à la segmentation fonctionnelle des images IRM du cerveau pour analyser les tumeurs cérébrales. En utilisant des réseaux de neurones profonds, ces chercheurs ont réussi à améliorer considérablement le processus de détection des tumeurs cérébrales. Les réseaux neuronaux peuvent détecter des lésions cérébrales en analysant des milliers d'images IRM, ce qui entraîne des améliorations significatives dans la précision de la détection et la réduction du temps nécessaire pour effectuer le diagnostic.

- ✓ Dans une étude menée par Toğaçar, Erğen et Cömert, ils ont utilisé un ensemble de données comprenant 253 images IRM provenant de Kaggle. Ils ont appliqué une méthode basée sur l'utilisation de super colonnes, de modules d'attention et de blocs résiduels pour procéder à la détection et à la classification des tumeurs cérébrales. Les résultats obtenus ont montré une précision de 96,05%, prouvant l'efficacité de cette méthode pour segmenter avec précision les tumeurs cérébrales à partir d'images IRM.
- ✓ Dans une autre étude menée par Özyurt, Sert, Avci et Dogantekin (2019), une méthode hybride utilisant des réseaux neuronaux et convolutifs (NS-CNN) a été appliquée. Les chercheurs ont utilisé les données de la collection Cancer Genome Atlas du glioblastome (TCGA-GBM) disponibles dans les archives d'imagerie du cancer (TCIA). Les résultats ont montré une précision moyenne de 95,62% dans la classification des tumeurs.

Nous avons résumé les travaux de plusieurs chercheurs et leurs méthodes de détection des tumeurs dans le tableau suivant :

Auteurs	Méthodes	Dataset	Evaluations
B kokilia, et al (2021) [39]	U-Nt et resNET	3064 images Kaggal	Accuracy = 92 %
Esraa Salah Bayoumi, et al (2022) [40].	AlexNet, Vgg16, Goo-gLeNet et Resnet50, Inceptionv3	RIDER Neuro MRI 349 images IRM	Accracy =99.56%
Amran Hossain, et al (2021) [41].	YOLOv3 (DCNN)	1000 images BRATS	Accuracy=95.62%
Rehman, Khan, Saba, et al (2021) [42].	3D CNN	BraTS databases	Accuracy=92.67%
Hari Mohan Rai, et al (2021) [43].	UnetResNext-50	kaggle	Accuracy=99.7%
Nivea Kesav, M.G Jibukumar (2021) [44].	RCNN	datasets Figshare et Kaggle	Accuracy=98.21%
Tariq Sadad Amjad Rehman Asim Munir (2020) [45].	Unet architecture et ResNet50	data set Figshare	Accuracy=95 %
Tingting Liu, et al [46].	CNN	image database brats	Accuracy=94.77%
Santos,Dheiver et Santos (2022) [47].	MobileNetV2	Kaggle Dataset	Accuracy=89 %
Khawaldeh et al (2018) [48].	AlexNet CNN	Cancer Imaging Archive (TCIA)	Accuracy=91.16%
SarangSharma ,et al (2021) [49].	VGG19 model	dataset (Kaggle)	Accuracy=98%

Table 3.1: Travaux connexes sur la tumeur au cerveau. [50]

### 3.3 Difficultés liées à la segmentation des images cérébrales

La segmentation des images IRM cérébrales présente des défis uniques en raison des caractéristiques spécifiques de l'objet à segmenter, à savoir l'anatomie complexe et variée du cerveau. De plus, le processus d'acquisition d'images IRM peut introduire des artefacts, tels que des mouvements involontaires du patient, des variations de signal liées à l'équipement et des interférences électromagnétiques, qui compliquent la segmentation. Ces artefacts peuvent altérer l'image, rendant la distinction entre les différentes structures anatomiques difficile. Par conséquent, la segmentation des images IRM cérébrales nécessite des techniques spécifiques pour prendre en compte ces particularités et améliorer la précision et la fiabilité du processus.

### 3.4 Conclusion

Ce chapitre nous a permis de nous plonger dans la littérature existante sur l'imagerie médicale, en particulier pour le diagnostic des tumeurs cérébrales. Nous avons examiné différentes études qui ont utilisé des modèles d'apprentissage profond pour détecter les tumeurs cérébrales à partir d'image IRM. Cela nous a permis de comprendre les différentes approches qui ont été utilisées pour résoudre ce problème.

Dans le prochain chapitre, nous allons présenter notre stratégie innovante pour la détection des tumeurs cérébrales à partir des images IRM. Nous allons décrire les outils et les approches que nous allons utiliser, ainsi que le jeu de données que nous avons utilisé pour entraîner notre modèle.

## 4 Contribution et résultat

### 4.1 Introduction

Voyant l'évolution des techniques d'apprentissage en profondeur et l'émergence d'architectures plus complexes, il devient de plus en plus difficile de former ces modèles avec les ensembles de données limités disponibles dans le domaine médical. La taille réduite des données, leur variabilité et l'absence de détection précise posent des défis majeurs. Ainsi, il est crucial de concevoir des architectures plus simples mais puissantes qui puissent efficacement gérer la détection des tumeurs cérébrales. Dans ce contexte, notre approche se base sur un modèle d'apprentissage profond utilisant les réseaux U-Net.

### 4.2 Méthode proposée

Dans notre travail et pour créer un modèle d'apprentissage profond, nous avons passé par de nombreuses étapes et effectuer de nombreuses tâches. Tout d'abord, nous collectons données et retraitez-les à l'aide de l'augmentation des données. Ensuite, nous créons le modèle, puis effectuons une formation et une évaluation du modèle et enfin la prédiction comme le montre la figure 4.1.

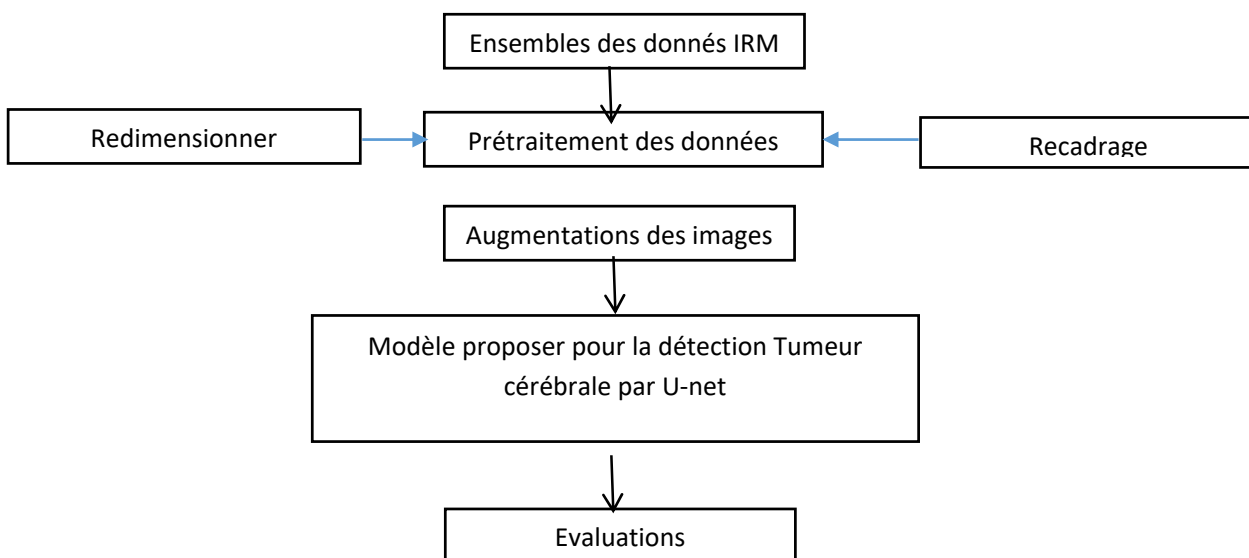


Figure 4.1: Architecture de méthode proposée

### 4.2.1 Ensemble de données IRM

Dans cette étude, l'ensemble de données IRM utilisé provient de Kaggle [39] étiqueté en deux leçons avec tumeur (Oui) et sans tumeur (Non). Données classées en types et collectés par des professionnels de la santé, par ex. Radiologues et médecins, avant d'être partagés en ligne. Aussi, beaucoup Des études ont été menées à partir de ces données.

La base de données est composée de trois mille images d'imagerie par résonance Imagerie par résonance magnétique (IRM) du cerveau, qui se présente sous différentes formes et tailles. Ces images ont été classées en deux catégories distinctes : tumorales et non tumorales. Il y a 1 500 images dans chaque classe, représentant respectivement la présence ou l'absence. De tumeurs. Les images ne sont pas de forme uniforme et la résolution des images est également différente.

La figure 4.2 illustre deux couches d'images étiquetées « Oui » pour ceux qui ont des tumeurs et « Non » pour ceux qui n'en ont pas.

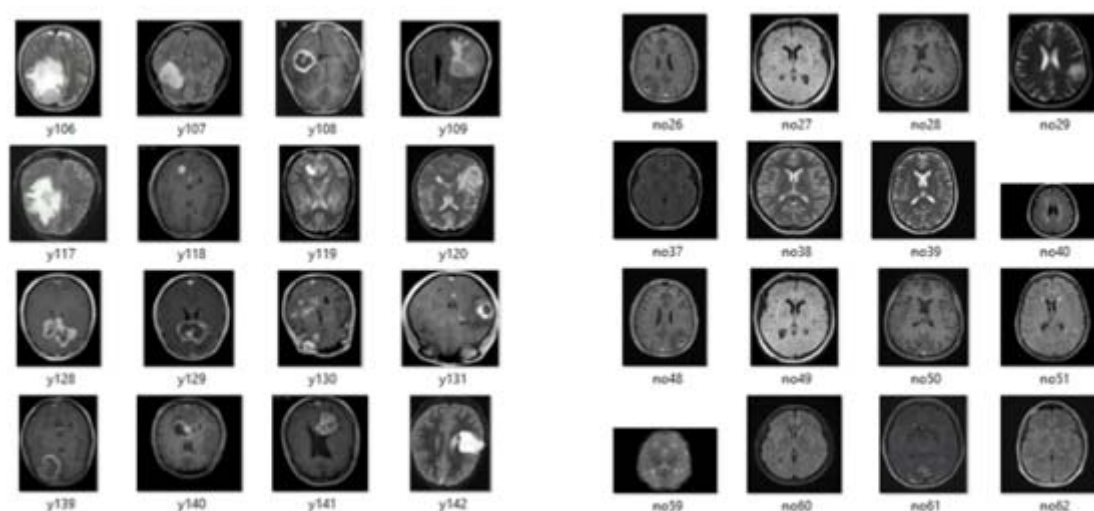


Figure 4.2: L'ensemble de données IRM.

### 4.2.2 Ensembles de données d'entraînement, de test et de validation

La répartition des ensembles de données en ensembles d'apprentissage, de test et de formation L'authentification est une méthode populaire en apprentissage profond. Cela nous permet d'évaluer et valider de manière indépendante les performances d'un modèle.

- - Ensemble d'entraînement : Le sous-ensemble est utilisé pour entraîner le modèle interne Ajustez ses paramètres et permettez-lui d'apprendre à reconnaître les schémas et motifs dans les données. Représente la majorité des données (70-80%) et est utilisé pour la phase de formation du modèle
- Ensemble de validation : Le sous-ensemble distinct est utilisé pour évaluer les performances du modèle pendant la formation. Cela aide à évaluer les capacités du modèle à généraliser sur des

données invisibles, à ajuster les hyperparamètres et à décider s'il faut arrêter l'entraînement plus tôt. Ce sous-ensemble représente généralement entre 10 et 20 % de l'ensemble d'entraînement.

- - Ensemble de test : Un sous-ensemble distinct est réservé à l'évaluation des performances finales du modèle après la formation. Il permet d'évaluer la capacité du modèle à généraliser et à classer de nouvelles données. Les données de test sont inconnues et ne doivent pas être utilisées pour ajuster le modèle ou prendre des décisions concernant ses paramètres afin d'éviter le surajustement.

Répartition des données entre sous-ensemble d'entraînement, test et validation. De nombreuses techniques d'apprentissage supervisé ne sont pas concernées uniquement par la comparaison de performances pour choisir le meilleur modèle. La plupart du temps, il y a également le besoin d'améliorer le modèle en réglant ses hyperparamètres (comme le nombre de couches cachées ou le nombre de neurones par couches). Si on fait un réglage de ces hyperparamètres sur le sousensemble de test, il y a un risque de surapprentissage ou overfitting du modèle.




Figure 4.3: représente l'évolution de l'erreur en fonction d'itérations durant les phases d'apprentissage, test et validation, afin d'illustrer la notion de surapprentissage et sous-apprentissage

### 4.2.3 Prétraitement des données

Le prétraitement des données est une étape importante pour garantir la qualité et pertinence des résultats de l'analyse des données. En normalisant les niveaux de gris et en redimensionnant les images, etc. La comparaison et l'extraction d'images sont plus faciles. Informations connexes. D'autres techniques de prétraitement peuvent également être utilisées pour améliorer la qualité et pertinence des résultats de l'analyse des données [50].

Description des données d'images Tous les examens multimodaux BraTS sont disponibles sous forme de fichiers NIfTI (.nii.gz) - un format d'imagerie médicale couramment utilisé pour stocker les données d'imagerie cérébrale acquises par IRM et caractériser les paramètres de l'IRM varient.

T1 : Acquisition 2D d'images natives pondérées T1, sagittales ou axiales, avec des épaisseurs de coupe de 1 à 6 mm.



T1c : imagerie avec contraste amélioré (Gadolinium) pondérée en T1 avec acquisition 3D et taille de voxel isotrope de 1 mm pour la plupart des patients.

T2 : Image pondérée T2, acquisition axiale 2D, avec une épaisseur de coupe de 2 à 6 mm.

FLAIR : Images FLAIR pondérées T2, acquisition 2D axiale, horizontale ou verticale, épaisseur de coupe de 2 à 6 mm.

Les données ont été collectées à l'aide de différents protocoles cliniques et de divers scanners de plusieurs institutions. Tous les ensembles de données d'images ont été segmentés manuellement, par un à quatre examinateurs, suivant le même protocole d'annotation, et leurs annotations ont été approuvées par des neuroradiologues expérimentés. Les annotations incluent une tumeur rehaussée par la GD (ET - étiquette 4), un œdème péri-tumoral (ED - étiquette 2) et un noyau tumoral nécrotique sans rehaussement (NCR/NET - étiquette 1), comme décrit dans l'article BraTS 2012-TMI 2013 et dans le dernier article de revue de BraTS. Les données fournies seront livrées après prétraitement, c'est-à-dire co-enregistrées sur le même modèle anatomique, interpolées à la même résolution ( $1 \text{ mm}^3$ ) et extraites du crâne-boîte.

#### 4.2.3.1 Recadrage d'images RM

Le découpage est nécessaire pour conserver uniquement les informations utiles et les supprimer. Les régions indésirables peuvent entraîner de mauvaises performances de classification proposer. Il est donc nécessaire de recadrer les images pour ce qu'elles ne contiennent que des informations utiles des informations utiles et les zones indésirables doivent être supprimées. Pour recadrer des images, calculer les points extrêmes et trouver leurs bordures utilisées, a été développé par Rosebrock [51]. Le processus de recadrage d'une image dans Chaque étape est illustré dans la figure 4.5.




Figure 4.4: Outil de recadrage des images RM.




Figure 4.5: Dataset après le recharge.




Figure 4.6 Afficher chaque tranche des données NIfTI 3D en les imprimant séparément. [52]

Charger des données médicales à partir de fichiers NIfTI pour l'entraînement d'un modèle. Il extrait les images FLAIR, T1, T1ce, T2 ainsi que le masque correspondant à partir des données volumiques. Ensuite, il crée une visualisation en affichant une tranche choisie au milieu de la troisième dimension pour chaque type d'image et de masque. Les images sont représentées en niveaux de gris pour une meilleure lisibilité.

#### 4.2.3.2 Redimensionnement des images

Ce processus de redimensionnement des images est nécessaire pour garantir des tailles cohérentes et effectuer les conversions nécessaires avant de les utiliser comme images. Comme entrée dans notre modèle, tout en préservant autant de fonctionnalités que possible et des détails importants

En ajustant la taille de l'image à des dimensions spécifiques de largeur, de hauteur et canaux (224 x 224 x 3), des résultats optimaux peuvent être obtenus avec le modèle, car il a été pré-entraîné sur des données contenant des images de ces dimensions, le redimensionnement des

images leur permet de s'adapter à la configuration prévue. Du modèle, vous permettant de profiter pleinement de ses capacités d'apprentissage. L'objectif principal de cette étape de redimensionnement est de garantir que tous Les images ont des tailles uniformes, garantissant la cohérence pendant le traitement donné du modèle. Cela permet d'éviter toute distorsion ou perte d'informations important lors de la conversion d'images. Bref, changer la taille de l'image à une taille spécifique est une étape importante dans la préparation de vos données d'entrée modèle, garantissant une taille cohérente et préservant les caractéristiques de base de l'image.




Figure 4.7 : Les images IRM redimensionnées.

#### 4.2.3.3 Augmentation des images

L'augmentation des données (DA) a été utilisée pour générer l'ensemble de données artificiellement en modifiant l'ensemble de données d'origine. AD implique la création plusieurs copies de l'image originale avec des orientations différentes. Pour chaque image, Des modifications ont été apportées à l'image originale pour créer une image améliorée. La figure 4.8 montre un exemple visuel de cette augmentation des données. Au-dessus d'image, l'image originale s'affiche comme avant. En bas de la figure, quelques images Les images augmentées présentées sont des variations des images originales à partir desquelles elles ont été créées. Les transformations sont appliquées. Ces images augmentées permettent d'introduire des variations

supplémentaires dans l'ensemble de données, ce qui peut aider le modèle à mieux généraliser et à être plus robuste aux variations présentes dans les données réelles.




Figure 4.8: Technique d'augmentation sur l'image originale

Dans notre étude, nous avons appliqué la technique d'augmentation des données à pour lutter contre le suréquippement. Cette méthode a été utilisée sur l'ensemble de données se compose de 3000 images dans le but de créer un nombre important d'images pour former. Il existe plusieurs techniques d'augmentation des données que nous avons implémentées à l'aide d'un générateur de données d'image et de fonctions de flux avec Python. Parmi ces techniques, nous avons utilisé la rotation, la largeur et la translation. Hauteur, recadrage, variation de luminosité, inversion horizontale et verticale, ainsi que des fonctions de prétraitement. En échantillonnant parmi 3000 échantillons disponibles, Nous avons appliqué ces huit techniques d'amélioration pour en générer 21 simultanément de nouvelles images. Cela nous permet d'enrichir notre jeu de données et de l'enrichir performance de nos modèles d'apprentissage.

### 4.3 Architecture U-net

#### 4.3.1 Réseau U-net de base

L'idée principale derrière CNN est d'apprendre le mappage des caractéristiques des images. Cela fonctionne très bien dans les problèmes de classification où les images sont converties en vecteurs qui sont ensuite utilisés pour la classification. Mais dans la segmentation d'image, il

faut non seulement la convertir en vecteur, mais aussi reconstruire l'image à partir de ce vecteur. C'est une tâche énorme, car convertir un vecteur en image est beaucoup plus difficile que l'inverse. Toute l'idée d'U-Net tourne autour de cette question. U-Net, dérivé du réseau neuronal traditionnel CNN, a été conçu et appliqué pour la première fois en 2015 pour le traitement d'images biomédicales. Il permet de localiser et de distinguer les contours des éléments qui composent une image donnée en les classant pixel par pixel. Détaillons l'architecture de ce modèle pour comprendre comment il fonctionne et ce qui le rend si précis et adaptable à ces situations complexes. [53]




Figure 2.3. Architecture de base du réseau U-Net. [54]

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

Le premier bloc, également appelé encodeur, permet de récupérer le contexte de l'image. Ce bloc se compose d'un ensemble de couches convolutives et de couches de pooling maximum pour capturer les caractéristiques de l'image et réduire sa dimensionnalité afin de réduire le nombre de paramètres de réseau. Cela implique l'application itérative de deux couches convolutives 3x3. Chaque couche est suivie d'une fonction d'activation ReLU et d'une normalisation par lots. Ensuite, une opération de pooling maximum 2x2 est appliquée pour réduire la dimension spatiale.

Le pont, également appelé goulot d'étranglement, relie les réseaux d'encodeurs et de décodeurs et complète le flux d'informations. Il se compose de deux couches convolutives 3x3, où chaque couche est suivie d'une fonction d'activation ReLU. Le deuxième bloc est le bloc de décodage. Il permet une localisation précise grâce à la transformation convolutionnelle et peut également retrouver la taille originale de l'image [55]. Le bloc de décodage commence par un rééchantillonnage de la carte des caractéristiques, suivi d'une couche convolutive 2x2 transformée. Ensuite, deux couches convolutives 3x3 sont utilisées, où chaque couche d'activation convolutive est suivie d'une fonction ReLU. La sortie du décodeur passe enfin par une couche convolutive 1x1 avec une fonction d'activation sigmoïde [55].

U-Net utilise une fonction de perte pour chaque pixel de l'image. La fonction Softmax est appliquée à chaque pixel suivi d'une fonction de perte. Cela transforme le problème de segmentation en un problème de classification où nous devons classer chaque pixel dans l'une des classes.

#### ***4.3.1.1 Variantes de U-Net***

Il existe de nombreuses applications de segmentation d'images utilisant U-Net, et il existe également plusieurs variantes de ce réseau, des versions améliorées ou adaptées à des cas très spécifiques. Nous prendrons quelques exemples :

#### ***4.3.1.2 3D-Unet :***

A été introduit peu de temps après U-net pour le traitement des volumes. On ne parle plus de pixels, mais plutôt de voxels. Son architecture est similaire à l'U-net traditionnelle, mais les couches convolutives sont 3x3x3, 2x2x2 ou 1x1x1 (tridimensionnelles). Ce modèle peut être entraîné directement sur des images 3D, sans qu'il soit nécessaire de s'entraîner sur chaque tranche séparément.

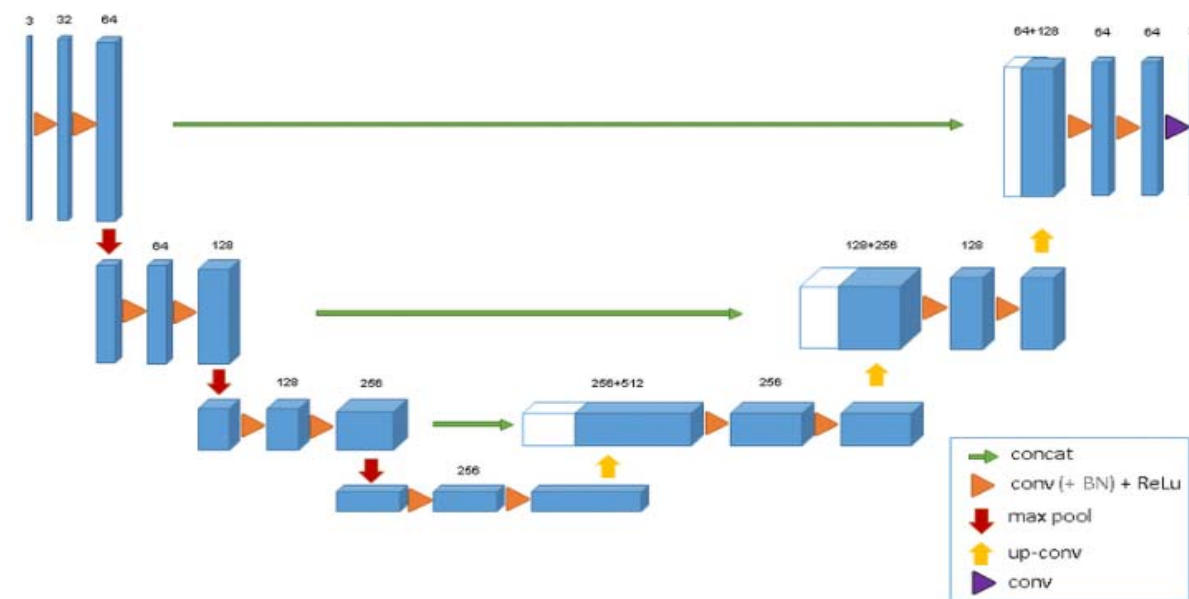


Figure 2.4. Architecture 3D-U-Net [56]

#### 4.3.1.3 V-Net : Ce modèle est très similaire à 3D-U-net, conçu pour les données 3D.

L'innovation de ce réseau est :

- Donne une erreur résiduelle (fonction de perte de dés).
- A chaque étape, V-Net applique la méthode de connexion par court-circuit de ResNet.
- La couche convolutive alterne suréchantillonnage et sous-échantillonnage

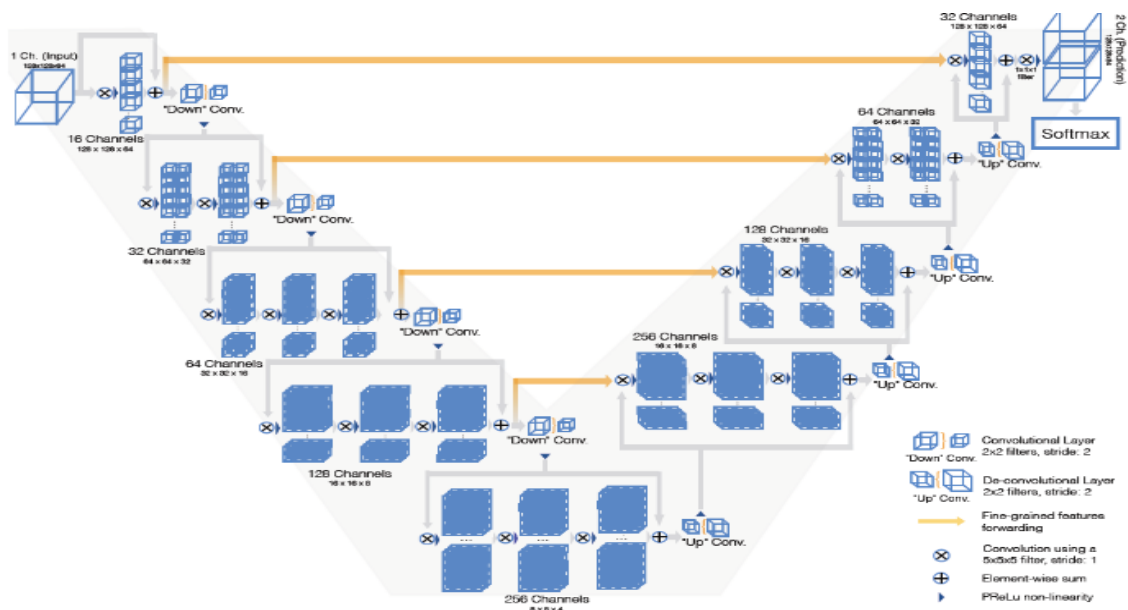


Figure 2.5. Architecture V-U-Net [57]



#### 4.3.1.4 UNet++ :

Visé à améliorer la précision de la segmentation en incluant des couches convolutives denses directement entre l'encodeur et le décodeur. Dans l'image ci-dessous, la partie noire représente la grille traditionnelle en forme de U-net. La partie verte représente des couches supplémentaires. Le nombre de paramètres ainsi que le temps de formation du réseau sont nettement plus élevés. C'est la principale raison pour laquelle il n'existe pas d'architecture similaire avec des structures 3D.




Figure 2.6. Architecture U-Net++ [58]

Il existe d'autres variantes telles le No New U-Net, Le U-Net récurrent, le U-Net dense et le U-Net résiduel basé sur le ResNet

#### 4.3.2 Avantages du U-Net :

Un avantage très important d'U-Net est qu'il peut effectuer une segmentation d'image en prédisant l'image pixel par pixel.

- Le réseau est suffisamment robuste pour faire de bonnes prédictions basées sur peu de données d'entraînement en utilisant des techniques de suraumentation des données. Il offre également une plus grande précision que les modèles conventionnels.
- En plus de sa robustesse, U-Net dispose également d'une architecture simple basée sur un auto-encodeur et des couches convolutives faciles à implémenter.
- Il existe plusieurs variantes de ce réseau qui s'adaptent à différentes situations, certaines très précises, d'autres très rapides.



U-Net est une architecture réseau conventionnel pour une segmentation d'image rapide et précise. Jusqu'à présent, elle a surpassé toutes les méthodes précédentes, notamment dans le domaine médical et dans la détection des anomalies et des tumeurs.

## 4.4 Le modèle proposé

### 4.4.1 Créer un modèle U-Net : Réseaux de convolution pour la segmentation d'images biomédicales

U-Net est une architecture de réseau convolutionnelle utilisée pour segmenter les images rapidement et avec précision. Jusqu'à présent, elle a surpassé la meilleure méthode précédente (réseau convolutif à fenêtre glissante) dans le défi ISBI visant à segmenter la structure neuronale dans une pile d'images au microscope électronique. Il a remporté le Grand Challenge for Automated Caries Détection with Interdental Radiograph à l'ISBI 2015, et il a également remporté le Cell Tracking Challenge à l'ISBI 2015 dans deux catégories de verre, la microscopie à lumière transmise la plus difficile (microscopie à contraste de phase et DIC) avec une avancée significative.

Le modèle optimal a été formé avec une précision moyenne de 81 % pour l'IOU et de 65,5 % pour la perte de dés. Au lieu de le recycler.

- **Entrées** : Les entrées du modèle U-Net sont généralement des images médicales en niveaux de gris ou en couleur, telles que des IRM ou des scanners. Ces images servent de données brutes à partir desquelles le modèle apprend à effectuer la segmentation.
- **Sorties** : Les sorties du modèle U-Net sont des masques de segmentation qui indiquent la classification de chaque pixel de l'image d'entrée. Typiquement, ces masques sont binaires, où chaque pixel est classé comme appartenant à la classe cible (par exemple, une tumeur) ou non. Ainsi, pour chaque pixel de l'image d'entrée, la sortie du modèle indique s'il fait partie de la structure segmentée ou non.
- **Fonctionnement** : Le U-Net fonctionne en prenant une image en entrée, puis en appliquant une série de couches de convolution, de regroupement (pooling), et de déconvolution pour extraire des caractéristiques et effectuer une segmentation précise. Contrairement à d'autres architectures, le U-Net utilise des connexions en saut (skip connections) qui permettent de préserver les informations spatiales à différentes

échelles, ce qui est particulièrement utile pour la segmentation d'images où la localisation précise des structures est importante.

Les entrées du modèle U-Net sont des images médicales, et les sorties sont des masques de segmentation qui identifient les structures d'intérêt dans ces images.

## 4.5 Environnement d'implémentation

Dans cette section, nous présentons les outils (matériel et logiciel) que nous avons utilisés dans notre travail

### 4.6 Logiciel

- **Kaggle** : une filiale de Google, est une communauté en ligne qui regroupe des données scientifiques et praticiens de l'apprentissage automatique. Il offre un environnement basé sur le Web pour la recherche, la publication et l'exploration de données, ainsi que plutôt que de créer des modèles. Kaggle permet également la collaboration, la participation à des concours de science des données et propose Kaggle Kernels, un atelier cloud pour partager du code et analyser en Python.
- **Python** : est un langage généraliste et largement utilisé en raison de sa compatibilité avec de nombreuses plates-formes et systèmes différents. Sa vaste bibliothèque et sa communauté active fournissent de nombreuses fonctionnalités, Framework et outils open source Améliorez la productivité des développeurs. Python est populaire dans l'apprentissage automatisé, big data et science des données. Dans notre travail, nous avons utilisé spécifiquement Python 3.7, la version par défaut de Colab [59].
- **Jupyter** : est un environnement interactif utilisé pour développer du code, analyse des données et reporting. Il vous permet de combiner du code, visualisations et textes dans des documents appelés « cahiers ». Carnet de notes Jupyter facilite l'exploration des données et la collaboration entre les utilisateurs. Nous présentons ici la bibliothèque la plus importante que nous avons utilisée :
- **Tkinter** : est une bibliothèque Python intégrée qui vous permet de créer des interfaces graphiques pour applications Il fournit des outils pour créer des fenêtres, boutons, champs de texte, barres de défilement et autres éléments interface utilisateur.
- **Latex** : est un programme de composition de documents et est considéré comme la norme de travail pour la communication et la publication d'articles scientifiques.
- **Collaborate (Colab)** : est un produit Google Research qui permet d'écrire et exécutez le code Python via le navigateur sans configuration. Il a suggéré accès gratuit aux GPU

et facilite le partage de projets [44]. Nous le présentons ici les bibliothèques les plus importantes que nous avons utilisées :

- **Keras** : est une interface de programmation d'application (API) conviviale conçue pour simplifier le processus de création, de formation et de déploiement de modèles étudier soigneusement. Il fournit des API cohérentes et simples, réduisant le volume l'action requise de l'utilisateur et fournir des messages d'erreur clairs. Avec une documentation complète et des conseils aux développeurs, Keras permet les utilisateurs se concentrent sur la conception de modèles plutôt que sur la saisie détails techniques de mise en œuvre [60].
- **Numpy (Numerical Python)** : est une bibliothèque open source qui fournit Fonctions mathématiques complètes, générateurs de nombres aléatoires, routines d'algèbre linéaire, transformations de Fourier, et bien plus encore. La bibliothèque NumPy vous permet de manipuler efficacement des tableaux de données multidimensionnelles, ce qui en fait un outil essentiel pour les calculs numériques internes Python [61].
- **TensorFlow** : est une plateforme d'apprentissage automatique open source fournit un écosystème complet et flexible pour créer et déployer des applications basées sur l'apprentissage automatique [62].

## 4.7 La phase d'évaluation

Le modèle de détection proposé a été formé sur des itérations (époques) en utilisant une diviser les données en apprentissage et évaluation. Les données ont été réparties d'une manière à louer 80 % des données pour entraîner le modèle, tandis que les 20 % restants sont réservés à l'évaluation des performances du modèle. De plus, nous avons suivi notre entraînement sur Google Colab en utilisant l'exécution GPU (Graphical Processing Unit) pour résultats rapides.

Pour évaluer l'efficacité de la détection des tumeurs, nous avons utilisé tous les données des images reconstruites proposées. Certains paramètres d'évaluation comprennent : La précision (P), l'exactitude – Accuracy- (A), le score F1 et la sensibilité (rappel) sont utilisés pour Testez le modèle entraîné. Ces paramètres permettent d'évaluer différentes mesures de performances du modèle, y compris sa capacité à détecter avec précision les tumeurs. Chacun de ces paramètres joue un rôle spécifique dans l'évaluation de la qualité du produit détecter les tumeurs.

- **La Précision** : La précision mesure la proportion d'observations positives prédites correctement parmi toutes les observations prédites comme positives. La précision

indique la capacité du modèle à minimiser les erreurs de classification des observations positives.

- **L'exactitude – Accuracy-** : mesure la fréquence à laquelle un modèle de classification produit des résultats Prédiction précises, qu'elles soient positives ou négatives. La précision fournit une évaluation globale des performances du modèle qui prend en compte à la fois les vrais et les positifs et les vrais points négatifs
- **Recall** : mesure la capacité d'un modèle à trouver avec précision des images positives. C'est le rapport entre le nombre d'images de tumeurs correctement classées et le nombre image de la tumeur entière. La sensibilité élevée montre que ce modèle est efficace pour détecter les images de tumeurs, car il minimise le nombre de faux négatifs, c'est-à-dire Les images tumorales sont classées à tort comme non tumorales.
- **Score F1** : est une mesure de la précision globale d'un test. Il est calculé en prenant Sens harmonieux de précision et de rappel. Précision de mesure de l'échelle résultats corrects parmi les résultats prédits, tandis que le rappel mesure le rapport résultat correct parmi tous les résultats réels.

Les critères d'évaluation et leur calcul sont présente comme suit :

$$\begin{aligned}
 \text{❖ Précision (P)} &= \frac{\text{Vrais positifs}}{\text{Vrais positifs} + \text{Faux positifs}} \\
 \text{❖ Exactitude (Accuracy)} &= \frac{\text{Vrais positifs} + \text{Vrais négatifs}}{\text{Total des échantillons}} \\
 \text{❖ Recall} &= \frac{\text{Vrais positifs}}{\text{Vrais positifs} + \text{Faux positifs}} \\
 \text{❖ Score F1} &= 2 * \frac{\text{Précision} + \text{Rappel}}{\text{Précision} + \text{Rappel}}
 \end{aligned}$$

Dans ces formules :

Les "Vrais positifs" sont les cas où le modèle a correctement prédit la présence d'une tumeur.

Les "Faux positifs" sont les cas où le modèle a prédit à tort la présence d'une tumeur.

Les "Vrais négatifs" sont les cas où le modèle a correctement prédit l'absence de tumeur.

Les "Faux négatifs" sont les cas où le modèle a prédit à tort l'absence de tumeur.

Le "Total des échantillons" est la somme de tous les cas positifs et négatifs.

## 4.8 Analyse des Résultats et Échanges

Le « train set », ou ensemble d'entraînement, est une partie des données utilisées pour entraîner un modèle d'apprentissage automatique. Il est composé d'exemples étiquetés sur lesquels le modèle apprend à partir des caractéristiques présentes dans les données et des étiquettes associées. L'objectif principal du train set est de permettre au modèle d'acquérir une compréhension des motifs et des relations présentes dans les données, afin qu'il puisse généraliser et faire des prédictions précises sur de nouvelles données similaires.

Le « val set », ou ensemble de validation, est une autre partie des données qui est utilisée pour évaluer les performances du modèle pendant l'entraînement. Contrairement au train set, le val set n'est pas utilisé pour ajuster les paramètres du modèle. Au lieu de cela, il sert à estimer les performances du modèle sur des données qu'il n'a pas encore vues et à fournir un indicateur de la façon dont le modèle généralise sur de nouvelles données. En utilisant le val set, les praticiens peuvent surveiller la performance du modèle au fur et à mesure de son entraînement et prendre des décisions telles que l'arrêt de l'entraînement lorsque la performance cesse de s'améliorer ou commence à se dégrader.

### Précision du Modèle (Model Accuracy) :

- La précision du modèle mesure la proportion d'observations correctement classées parmi toutes les observations.
- Elle fournit une évaluation globale des performances du modèle, prenant en compte à la fois les vrais positifs et les vrais négatifs.
- Une précision élevée indique que le modèle fait des prédictions correctes dans une large mesure.

### Model Loss :

- La perte du modèle, ou la fonction de perte, mesure à quel point les prédictions du modèle sont éloignées des vraies étiquettes dans un ensemble de données.
- Elle fournit une indication de l'erreur moyenne du modèle sur l'ensemble de données.
- Une perte faible indique que le modèle fait des prédictions précises et est capable de minimiser l'erreur.

## Comparaison :

- **Interprétation** : La précision du modèle est souvent plus intuitive pour interpréter les performances globales du modèle, car elle fournit directement la proportion de prédictions correctes. En revanche, la perte du modèle donne une indication de la qualité des prédictions en termes d'erreur moyenne.
- **Objectif** : L'objectif est de maximiser la précision du modèle tout en minimisant sa perte. Cependant, ces deux mesures peuvent parfois être en contradiction, car un modèle peut avoir une précision élevée tout en ayant une perte relativement élevée, et vice versa.
- **Utilisation** : La précision du modèle est souvent utilisée pour évaluer les performances finales du modèle sur un ensemble de données de test, tandis que la perte du modèle est utilisée comme métrique d'optimisation pendant l'entraînement pour guider l'ajustement des paramètres du modèle.

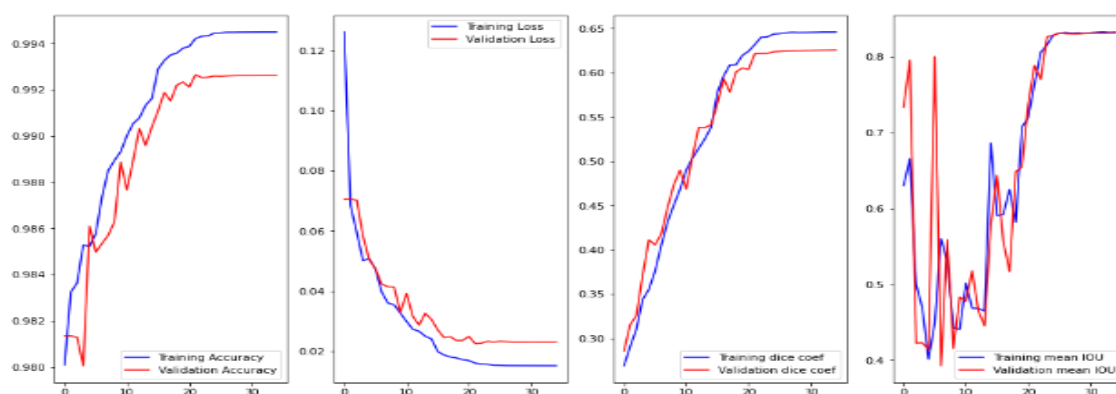
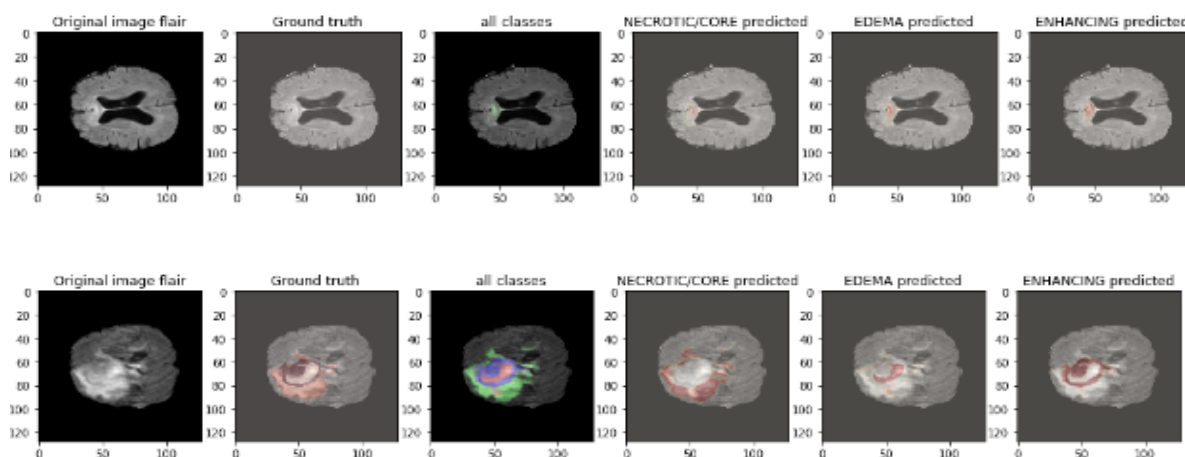



Figure Analyse de l'entraînement du modèle : une approche visuelle

## 4.9 La prédiction

### 4.9.1 Le fonctionnement de l'application

Exemple de prédiction





## 4.10 Conclusion

Dans ce chapitre, nous avons abordé l'architecture de notre proposition de modèle, appelé U-net, qui repose sur des composants de réseaux de neurones convolutionnels (CNN), ainsi que les méthodes de travail et les processus associés. Ensuite, nous avons décrit les technologies utilisées pour implémenter notre application, notamment le langage de programmation et le Framework. Enfin, nous avons présenté les métriques d'évaluation de notre modèle suggéré, démontrant que notre approche a produit des résultats exceptionnels comparables aux méthodes actuelles

## Conclusion générale

---

La détection des tumeurs cérébrales nécessite la synthèse d'une variété d'informations, non seulement à partir d'images, mais également de données textuelles sur l'anatomie et les fonctions liées aux structures cérébrales et aux maladies qui les influencent. Les experts combinent ces informations pour établir un diagnostic précis et fiable. Le but de ce travail est de modéliser ce processus à l'aide de méthodes de segmentation, afin de fournir un outil de segmentation, de mesure volumétrique et de quantification fonctionnelle des tumeurs cérébrales. Après avoir effectué une revue de la littérature sur la segmentation des tumeurs cérébrales dans les chapitres précédents, nous avons souligné son importance et les défis liés à cette tâche. Deux raisons expliquent ces difficultés :

- Premièrement, il existe de nombreux types de tissus anormaux qui varient en taille, forme, emplacement et composition (propriétés et uniformité). De plus, dans certains cas, la forme des structures peut être difficile à distinguer même pour les experts.
- La deuxième raison vient des données d'acquisition IRM, qui sont sensibles au bruit de fond et à l'échantillonnage. Par conséquent, un voxel peut contenir des informations provenant de différents types de tissus, ce qui provoque ce que l'on appelle l'effet de volume partiel.

Notre recherche se concentre sur les méthodes de segmentation des tumeurs cérébrales en imagerie par résonance magnétique, un aspect crucial des études cliniques où la mesure précise du volume de la lésion est utilisée comme biomarqueur. Pour cette tâche, nous avons adopté l'architecture U-Net, une approche bien établie et efficace dans le domaine. Le choix d'utiliser les réseaux de neurones convolutionnels (CNN) comme méthode de segmentation repose sur leur simplicité et leur efficacité, une approche qui a prouvé son efficacité au fil des années

Les résultats obtenus grâce à l'approche U-Net de réseau CNN ont été concluants démontrant l'efficacité de cette méthode pour détecter les tumeurs cérébrales dans des images IRM. Cela donne de nouvelles opportunités dans le domaine de détection des tumeurs, L'imagerie médicale, qui permet un diagnostic précoce et précis des maladies cérébrales, peut avoir un impact significatif sur le traitement et le pronostic des patients.



## Bibliographie

- [1] Anthony, J. (1946). Morphologie externe du cerveau des singes platyrrhiniens. Annales des Sciences Naturelles.
- [2] Wiest-Daesslé, N. (2009). Imagerie du tenseur de diffusion pour l'étude de pathologies cérébrales. Rapport thèse de doctorat.
- [3] Janet, P. (1867). Le cerveau et la pensée. Baillière.
- [5] Barral, J.-P. (2021). Approche ostéopathique du cerveau. Elsevier Health Sciences.
- [6] Aquaportail. (s.d.). Cervelet. Récupéré sur <https://www.aquaportail.com/dictionnaire/definition/11996/cervelet>
- [7] Paxinos, G., & Huang, X.-F. (2013). Atlas of the human brainstem. Elsevier.
- [8] Thomas, D. (2018). La définition de tronc cérébral. Carnets2psycho.
- [9] Boussemi, R. S., & Kenadil, M. (2011). Segmentation des tumeurs cérébrales par la ligne de partage des eaux sur des images IRM. Mémoire de projet de fin d'étude pour l'obtention du diplôme de Master en Électronique Biomédicale.
- [10] Jeretiens. (s.d.). Comprendre le cerveau : Comment fonctionne-t-il et de quoi est-il composé? Récupéré sur <https://jeretiens.net/comprendre-le-cerveau-comment-fonctionne-t-il-et-de-quoi-est-il-compose/>
- [11] Azocli, T. (2018). Relation entre leucorachie et méningite bactérienne. EPAC/UAC.
- [12] Germond, L. (1999). Trois principes de coopération pour la segmentation en imagerie de résonance magnétique cérébrale. Thèse de doctorat, spécialité : Informatique, Université Joseph Fourier – Grenoble.
- [13] Florence, G. (2004). Geneviève. La physiologie de la circulation cérébrale. Bulletin de l'Académie Vétérinaire de France, 19-30.
- [14] Michelle. (2022). Le système immunitaire du cerveau, la microglie, les vaccins, l'immunothérapie. France : Le Magazine Mensuel d'IBTA.
- [15] Oncoilogy, J. (2020). Benign vs malignant tumors. Récupéré sur <https://www.oncoilogy.com/benign-vs-malignant-tumors>
- [16] Alamy. (2020). Malignant tumor photos stock & des images. Récupéré sur <https://www.alamyimages.fr/photos-stock/malignant-tumor.html>
- [17] Hoang-Xuan, K., Peyre, M., Feuvret, L., & al. (2015). Les Cancers du cerveau. Collection Comprendre et Agir.
- [18] Tshikewla, L. L., Malenga, M., Molua, A., & al. (1993). L'imagerie médicale par le scanner à rayons X: Définition; principes; indications. Congo Médical.
- [20] BrainWeb. (2020). Volumes d'IRM simulés pour un cerveau normal. Récupéré sur <https://brainweb.bic.mni.mcgill.ca/cgi/brainweb1>
- [21] Chatelain, R., Hérault, C., & Clément. (2021). Construisez des modèles génératifs grâce aux réseaux de neurones. OpenClassrooms.

- [22] Horáková, T., Houska, M., & Domeova, L. (2017). Classification of the educational texts styles with the methods of artificial intelligence. *Journal of Baltic Science Education*.
- [23] Lawler, R. W., & Rushby, N. (2013). An interview with Robert Lawler. *British Journal of Educational Technology*.
- [24] Batta, M. (2020). Machine learning algorithms-a review. *International Journal of Science and Research (IJSR)*.
- [25] Mhammedi, A., Yakoub, I., & Ouahab, A. (2021). La détection de Covid-19 par l'apprentissage profond (Deep Learning). Thèse de doctorat, Université Ahmed Draia Adrar.
- [26] Itsvit. (2019). Short guide on how Deep Learning really works. Récupéré sur <https://itsvit.com/blog/deep-learning-how-it-works/>
- [27] Gobiniet, C., & Vrabie, V. (2008). Prétraitements et méthodes de séparation de sources pour l'analyse des spectres Raman issus d'échantillons biologiques. *Preprocessing and Source Separation Methods for Raman Spectra Analysis of Biomedical Samples*.
- [28] Rosebrock, A. (2020). Finding extreme points in contours with OpenCV. *PyImageSearch*. Récupéré sur <https://www.pyimagesearch.com/2020/06/01/finding-extreme-points-in-contours-with-opencv/>
- [29] Kaggle. (s.d.). 3D MRI Brain Tumor Segmentation U-Net. Récupéré sur <https://www.kaggle.com/code/rastislav/3d-mri-brain-tumor-segmentation-u-net/notebook>
- [30] Mahesh, B. (2008). Machine learning algorithms - a review. *International Journal of Science and Research (IJSR)*.
- [31] Mhammedi, A., Yakoub, I., & Ouahab, A. (2021). La détection de Covid-19 par l'apprentissage profond (Deep Learning). Thèse de doctorat, Université Ahmed Draia Adrar.
- [32] Itsvit. (2019). Short guide on how Deep Learning really works. Récupéré sur <https://itsvit.com/blog/deep-learning-how-it-works/>
- [33] Gobiniet, C., & Vrabie, V. (2008). Prétraitements et méthodes de séparation de sources pour l'analyse des spectres Raman issus d'échantillons biologiques. *Preprocessing and Source Separation Methods for Raman Spectra Analysis of Biomedical Samples*.
- [35] Natural Solutions. (s.d.). Histoire du deep learning. Récupéré sur <https://www.natural-solutions.eu/blog/histoire-du-deep-learning>
- [36] Wang, H., Raj, B., & Xing, E. P. (2017). On the origin of deep learning. *ArXiv preprint arXiv*.
- [37] Moualek, D. (2017). Deep Learning for Image Classification. Doctoral thesis, Abu Bakr Belkayad University, Tlemcen.
- [38] Benhizia, L., & Benbatata, S. (2021). Segmentation of Multiple Sclerosis in MR. *BBA*.
- [39] Medjdoubi, A. (2019). Sentiment analysis using deep learning. Master's thesis, Tahar Moulay University, Saida.
- [40] Kokila, B., Devadharshini, M. S., & Anitha. (2021). Brain Tumor Detection and Classification Using Deep. *Journal of Physics: Conference Series*, 012226.

- [41] Salah Bayoumi, E., Abd-Allah, M. K., & Gharieb, R. R. (2022). Brain Tumor Automatic Detection from MRI Images Using Transfer. *Advanced Engineering Trends*.
- [42] Hossain, A., Razouqi, Q., & Razouqi, Q. (2021). A YOLOv3 Deep Neural Network Model. *IEEE Access*.
- [43] Khan, A. R., et al. (2021). Brain tumor segmentation using K-means clustering and deep learning with synthetic data augmentation for classification. *Microscopy Research and Technique*, 84(7), 1389–139.
- [44] Rai, H. M., & Chatterjee, K. (2021). Automatic and accurate abnormality detection from brain MR images using. Elsevier.
- [45] Kesav, N., & Jibukumar, M. G. (2021). Efficient and low complex architecture for detection and classification. *Journal of King Saud University*.
- [46] Sadad, T., & Munir, A. R. A. (2020). Brain tumor detection and multi-classification using advanced. Wiley.
- [47] Santos, D., & Santos, E. (2022). Brain Tumor Detection Using Deep Learning. *medRxiv*.
- [48] Khawaldeh, S., et al. (2017). Noninvasive grading of glioma tumor using magnetic resonance imaging with convolutional neural networks. *Applied Sciences*.
- [49] Sharma, S., et al. (2022). Deep Learning Model for Automatic Classification and Prediction of Brain Tumor. *Hindawi*.
- [50] Rosebrock, A. (2020). Finding Extreme Points in Contours with OpenCV. *PyImageSearch*. Récupéré sur <https://www.pyimagesearch.com/2020/04/27/finding-extreme-points-in-contours-with-opencv/>
- [51] Kaggle. (s.d.). 3D MRI Brain Tumor Segmentation U-Net. Récupéré sur <https://www.kaggle.com/code/rastislav/3d-mri-brain-tumor-segmentation-u-net/notebook>
- [52] Rastislav, Code. (s.d.). 3D MRI Brain Tumor Segmentation U-Net. Récupéré sur <https://www.kaggle.com/code/rastislav/3d-mri-brain-tumor-segmentation-u-net/notebook>
- [53] Rosebrock, A. (2020). Finding extreme points in contours with OpenCV. *PyImageSearch*. Récupéré sur <https://www.pyimagesearch.com/2020/06/01/finding-extreme-points-in-contours-with-opencv/>
- [54] Kaggle. (s.d.). 3D MRI Brain Tumor Segmentation U-Net. Récupéré sur <https://www.kaggle.com/code/rastislav/3d-mri-brain-tumor-segmentation-u-net/notebook>
- [55] Blent AI. (s.d.). U-Net for Computer Vision. Récupéré sur <https://blent.ai/blog/a/unet-computer-vision>
- [56] Blent AI. (s.d.). U-Net for Computer Vision. Récupéré sur <https://blent.ai/blog/a/unet-computer-vision>
- [57] Blent AI. (s.d.). U-Net for Computer Vision. Récupéré sur <https://blent.ai/blog/a/unet-computer-vision>
- [58] Blent AI. (s.d.). U-Net for Computer Vision. Récupéré sur <https://blent.ai/blog/a/unet-computer-vision>
- [59] Python, Why. (2021). Python Releases Wind.

[60] Edelson, D. C., Pea, R. D., & Gomez, L. M. (1996). The collaboratory notebook. Communications of the ACM.

[61] Keras Team. (2022). Simple. flexible. powerful. Récupéré sur <https://keras.io/>

[62] Ascher, D., et al. (2001). Numerical Python.

## • Résumé

Le traitement des images médicales, notamment celles obtenues par imagerie par résonance magnétique (IRM), est important pour avoir un diagnostiquer certaines maladies telles que les tumeurs cérébrales. Dans cette étude, nous proposons une méthode pour détecter automatiquement ces tumeurs à l'aide du réseau U-Net. Notre approche repose sur l'utilisation de cette architecture pour extraire les caractéristiques distinctives des images IRM, qui sont ensuite utilisées pour la détection des tumeurs. Les résultats montrent que notre modèle basé sur U-Net atteint une précision de détection de 95 %, démontrant son efficacité dans ce contexte. Ces résultats montrent le potentiel prometteur de l'utilisation d'U-Net pour améliorer la détection précoce et précise des tumeurs cérébrales à partir des images IRM.

• Mots clés : IRM, U-net, segmentation, Apprentissage en profondeur, Tumeurs cérébrales.

## ملخص.

تعد معالجة الصور الطبية، وخاصة تلك التي يتم الحصول عليها عن طريق التصوير بالرنين المغناطيسي (MRI)، مهمة لتشخيص بعض الأمراض مثل أورام المخ. في هذه الدراسة، نقترح طريقة للكشف التلقائي عن هذه الأورام باستخدام شبكة U-Net. يعتمد نهجنا على استخدام هذه البنية لاستخراج السمات المميزة لصور التصوير بالرنين المغناطيسي، والتي يتم استخدامها بعد ذلك للكشف عن الورم. أظهرت النتائج أن نموذجنا المستند إلى U-Net يحقق دقة اكتشاف تبلغ 95%، مما يدل على فعاليته في هذا السياق. تظهر هذه النتائج الإمكانيات الواعدة لاستخدام U-Net لتحسين الكشف المبكر والدقيق عن أورام المخ من صور التصوير بالرنين المغناطيسي.

• الكلمات المفتاحية: التصوير بالرنين المغناطيسي، U-net، التجزئة، التعلم العميق، أورام المخ.

## • Abstract

The processing of medical images, especially those obtained by magnetic resonance imaging (MRI), is important for diagnosing certain diseases such as brain tumors. In this study, we propose a method to automatically detect these tumors using the U-Net network. Our approach is based on using this architecture to extract distinctive features from MRI images, which are then used for tumor detection. The results show that our U-Net-based model achieves a detection accuracy of 95%, demonstrating its effectiveness in this context. These results show the promising potential of using U-Net to improve the early and accurate detection of brain tumors from MRI images.

• Keywords: MRI, U-net, segmentation, Deep learning, Brain tumors.