

**RÉPUBLIQUE ALGÉRIENNE DÉMOCRATIQUE ET POPULAIRE**  
**MINISTÈRE DE L'ENSEIGNEMENT SUPÉRIEUR ET DE LA**  
**RECHERCHE SCIENTIFIQUE**



**Université 20 Aout 1955 - Skikda**

**FACULTÉ DES SCIENCES**

**DÉPARTEMENT D'INFORMATIQUE**

**MÉMOIRE DE FIN D'ÉTUDE**

**POUR L'OBTENTION DU DIPLÔME DE MASTER**

**OPTION : INTELLIGENCE ARTIFICIELLE**

---

**Détection et classification automatisées des tumeurs cérébrales à  
l'aide des techniques d'apprentissage profond**

---

*Présenté Par :*  
LEKOUÏ Cheima

*Supervisé Par :*  
Dr. Adel Lahsasna

**2023 - 2024**

## **Remerciements**

Louange à Allah, le Tout-Puissant, qui m'a accordé la foi, la force et la persévérance nécessaires pour mener à bien ce travail. Sans Ses bénédictions, rien de tout cela n'aurait été possible.

Je tiens à exprimer ma plus profonde gratitude à mon directeur de mémoire, le DR ADEL LAHSASNA de l'Université de Skikda, pour son soutien indéfectible, sa confiance, et ses conseils éclairés. Sa présence constante, ses remarques constructives et son encadrement ont été essentiels à la réalisation de cette recherche.

Je suis également reconnaissant envers toutes les personnes qui m'ont aidé à améliorer ce travail en partageant leurs remarques et suggestions.

Enfin, j'exprime ma gratitude à toutes celles et ceux qui, de près ou de loin, ont contribué au développement de ce mémoire.

Qu'Allah nous guide et nous bénisse tous.

## Dédicaces

*Je dédie ce travail à la meilleure personne qui m'a accompagné tout au long de mon voyage, qui m'a soutenu et a séché mes larmes dans mes moments de faiblesse, celle sur qui j'ai pu compter. Elle a été le meilleur soutien, le meilleur ami, et la meilleure personne. À moi-même, la combattante patiente et ambitieuse, celle qui a surmonté tant d'obstacles pour réussir, je dis : Bravo **Chifaa (Cheima)**.*

*Je dédie ce travail remarquable au meilleur père du monde, **IBRAHIM**, celui qui a tant donné de lui-même et m'a enseigné que le succès vient uniquement par la patience et la détermination. À cet homme cultivé et merveilleux, qui a été une encyclopédie vivante marchant sur terre, une icône scientifique rare, et doté d'une forte personnalité. Il nous a nourris alors que nous étions affamés, tandis qu'il lui-même était satisfait. À cet homme exceptionnel qui nous a quittés, laissant un vide incommensurable dans nos vies. Que Dieu ait son âme et lui accorde le paradis. Je dédie ce travail à **ma mère**, mon inspiration éternelle. Que Dieu la garde et prolonge sa vie.*

*Je dédie mon succès et cette réussite à **mon futur mari**, avec l'espoir d'être pour toi et notre future famille une source de fierté, si Dieu le veut. Je dédie également cette réussite à **mes futurs enfants**, mes précieux enfants. Vous aurez la chance d'avoir une mère dévouée, et je m'efforcerai de réussir pour que vous soyez fiers de moi, tout comme je serai fière de vous.*

*Je dédie ce succès à mes frères **MOHAMED, YACINE, AHMED, RAMZY**, les plus formidables et exceptionnels du monde, dont le soutien inconditionnel et l'amour fraternel ont été une source inépuisable de force et d'inspiration.*

*Je dédie ce succès à **mes sœurs**, les plus merveilleuses et exceptionnelles du monde, dont l'amour, le soutien indéfectible et la bienveillance ont toujours été une source de motivation et de force pour moi.*

*Je dédie ce succès À ma sœur et mon professeur **Umm Abderahmane**, qui a été pour moi comme une grande sœur que ma mère n'a pas mise au monde, À celle qui a été une amie fidèle, toujours présente dans mes moments de détresse, À celle vers qui je me tourne, confiante, lorsque le poids de la vie devient trop lourd, À ma sœur que j'aime d'un amour profond, indescriptible par les mots... Tu es bien plus qu'une sœur ou une amie : tu es l'âme qui m'inspire, le cœur qui me reconforte. Tu as toujours été la lumière dans mes moments d'obscurité. Merci d'être là, toujours, en tant que compagne fidèle et soutien infaillible.*

*Je dédie ma réussite à **mes beaux-frères et mes belles-sœurs**. Leur générosité et leur solidarité ont joué un rôle essentiel dans l'aboutissement de ce travail.*

*A tous **mes amis** qui m'ont toujours encouragé, et à qui je Souhaite plus de succès.*

*Je dédie ce succès à **mes neveux** et **nièces** bien-aimés. Vous êtes ma fierté et ma joie. J'espère être pour vous un modèle à suivre, et que vous continuerez à briller et à exceller dans tout ce que vous entreprendrez.*

*Je dédie ce succès à ma merveilleuse **équipe okol rajiha acadmie**, dirigée par la directrice **Umm Iyad**. Vous avez toujours été une source de soutien et d'encouragement, et je ne peux qu'exprimer ma profonde gratitude pour tout votre dévouement et votre sincérité. Merci pour vos efforts et votre coopération continue. L'esprit d'équipe a joué un rôle majeur dans la réalisation de cette réalisation.*

*Merci à tous.*

## ملخص

تُعتبر عملية الكشف وتصنيف أورام الدماغ من التحديات الكبيرة نظراً لتعقيد بنية الأورام وتنوع البيانات الناتجة عن التصوير الطبي. تهدف هذه الدراسة إلى تحسين دقة وموثوقية الكشف عن أورام الدماغ وتصنيفها من خلال الاستفادة من تقنيات التعلم العميق. تم استخدام مجموعة بيانات من صور الرنين المغناطيسي لأورام الدماغ لتطوير وتقييم نماذج متعددة، بما في ذلك خوارزميات التعلم الآلي التقليدية مثل الجيران الأقرب، وآلات الدعم المتجهية، والغابات العشوائية، وأدابوست، وطست، إلى جانب النماذج المتقدمة للتعلم العميق مثل موبايل نت، إفشينت نت، في جي جي ٩١، الشبكات العصبية التلافيفية، دينس نت، وريس نت إنسبشن. تم تقييم أداء النماذج باستخدام مؤشرات مثل الدقة، ومعامل سا، ومعامل الدقة، والاستدعاء، ومنحنى خصائص التشغيل للمستقبل، ومعامل كابا الخاص بـ كوهين. أظهرت النتائج التجريبية تفوق النماذج المعتمدة على التعلم العميق بشكل كبير على خوارزميات التعلم الآلي التقليدية. حيث حقق نموذج إفشينت نت دقة بلغت ٣.٩٩٪، ومعامل سا بقيمة ٩٩.٠، ومنحنى تشغيل بقيمة ٩٩.٠. تشير هذه النتائج إلى تحسينات كبيرة في الأداء التشخيصي، مما يبرز أهمية الأنظمة القائمة على التعلم العميق في تقليل الأخطاء التشخيصية وتعزيز كفاءة الكشف عن أورام الدماغ وتصنيفها.

## Résumé

La détection et la classification des tumeurs cérébrales présentent des défis considérables en raison de la complexité des structures tumorales et de la variabilité des données d'imagerie. Cette étude vise à améliorer la précision et la fiabilité de la détection et de la classification des tumeurs cérébrales en exploitant les techniques d'apprentissage profond. En utilisant un ensemble de données d'IRM de tumeurs cérébrales, nous avons développé et évalué plusieurs modèles, incluant des algorithmes d'apprentissage automatique traditionnels tels que les K-Nearest Neighbors (KNN), Support Vector Machines (SVM), Random Forest, Adaboost et XGBoost, ainsi que des architectures avancées d'apprentissage profond comme MobileNet, EfficientNetB0, VGG-19, CNN, DenseNet et ResNetInceptionV3. Les performances des modèles ont été évaluées à l'aide de métriques telles que la précision (accuracy), le F1 score, la précision (precision), le rappel (recall), l'AUC (ROC) et le score de Cohen's Kappa.

Les résultats expérimentaux ont démontré que les modèles d'apprentissage profond surpassent significativement les approches traditionnelles d'apprentissage automatique, avec EfficientNetB0 atteignant une précision de 99.3% , un F1 score de 0,99 et une AUC de 0,99. Ces résultats indiquent une amélioration substantielle des performances diagnostiques, suggérant que les systèmes basés sur l'apprentissage profond peuvent jouer un rôle crucial dans la réduction des erreurs diagnostiques et l'amélioration de l'efficacité de la détection et de la classification des tumeurs cérébrales.

**Mots-clés** : Détection des tumeurs cérébrales, apprentissage profond, apprentissage automatique, EfficientNetB0, CNN, KNN, Random Forest, précision, F1 score, AUC, images IRM.

## Abstract

The detection and classification of brain tumors present considerable challenges due to the complexity of tumor structures and the variability in imaging data. This study aims to enhance the precision and reliability of brain tumor detection and classification by leveraging deep learning techniques. Using a dataset of brain tumor MRI images, we developed and evaluated multiple models, including traditional machine learning algorithms such as K-Nearest Neighbors (KNN), Support Vector Machines (SVM), Random Forest, Adaboost, and XGBoost, alongside advanced deep learning architectures like MobileNet, EfficientNetB0, VGG-19, CNN, DenseNet, and ResNetInceptionV3. The models' performances were assessed using metrics such as accuracy, F1 score, precision, recall, ROC (AUC), and Cohen's Kappa score.

The experimental results demonstrated that deep learning models significantly outperformed traditional machine learning approaches, with EfficientNetB0 achieving an accuracy of 99.3%, an F1 score of 0.99, and an AUC of 0.99. These findings indicate a substantial improvement in diagnostic performance, suggesting that deep learning-based systems can play a pivotal role in reducing diagnostic errors and improving the efficiency of brain tumor detection and classification.

**Keywords :** Brain tumor detection, deep learning, machine learning, EfficientNetB0, CNN, KNN, Random Forest, accuracy, precision, F1 score, AUC, MRI images.

# Table des matières

|          |   |           |
|----------|---|-----------|
| <b>I</b> | <b>Partie 1</b>   | <b>15</b> |
| <b>1</b> | <b>Introduction</b>   | <b>16</b> |
| 1.1      | Contexte et Motivation . . . . .  | 17        |
| 1.2      | Structure du mémoire . . . . .  | 19        |
| <b>2</b> | <b>Revue de la littérature</b>  | <b>21</b> |
| 2.1      | Aperçu des Maladies Tumeurs Cérébrales . . . . .  | 22        |
| 2.1.1    | <b>Types et caractéristiques des tumeurs cérébrales</b> . . . . .   | 22        |
| 2.1.2    | <b>Méthodes Traditionnelles de Diagnostic et de Classification des Tumeurs Cérébrales</b> . . . . .             | 23        |
| 2.2      | Techniques d’Imagerie Medical . . . . .   | 24        |
| 2.2.1    | La matière grise . . . . .  | 24        |
| 2.3      | Travaux Antérieurs sur la Détection des Maladies tumeurs cérébrales Utilisant l’Apprentissage Profond . . . . . | 29        |
| 2.3.1    | <b>Travaux antérieurs dans l’analyse d’images médicales</b> . . . . .   | 29        |
| 2.3.2    | <b>Applications récentes dans la détection des tumeurs cérébrales</b> . . . . .                                 | 30        |
| 2.3.3    | Travaux Antérieurs sur la Détection des Maladies Cardiaques Utilisant l’Apprentissage Automatique . . . . .     | 30        |
| 2.4      | Conclusion . . . . .  | 31        |
| <b>3</b> | <b>LA METHODOLOGIE</b>  | <b>33</b> |
| 3.1      | Description des ensembles de données . . . . .  | 34        |
| 3.1.1    | <b>Techniques de prétraitement</b> . . . . .  | 35        |
| 3.2      | <b>Modèles d’Apprentissage Profond</b> . . . . .  | 36        |
| 3.2.1    | <b>Types d’apprentissage automatique</b> . . . . .  | 36        |
| 3.3      | Techniques d’apprentissage automatique couramment utilisées . . . . .   | 39        |
| 3.3.1    | Machine à vecteurs de support (SVM) . . . . .   | 39        |
| 3.3.2    | <b>K-plus proches voisins (KNN)</b> . . . . .   | 39        |
| 3.3.3    | <b>Réseau de neurones artificiels</b> . . . . .   | 40        |
| 3.3.4    | <b>Forêts aléatoires (Random Forest)</b> . . . . .  | 40        |
| 3.3.5    | <b>Arbres de décision (Decision Trees)</b> . . . . .  | 41        |
| 3.3.6    | <b>La régressionl logistique</b> . . . . .  | 41        |
| 3.3.7    | <b>AdaBoost Classifier</b> . . . . .  | 42        |
| 3.3.8    | <b>XGBoostClassifier(XGBClassifier)</b> . . . . .   | 43        |
| 3.4      | <b>Apprentissage Profond (Deep Learning)</b> . . . . .  | 43        |

|          |   |           |
|----------|---|-----------|
| 3.4.1    | <b>D'ensemble des modèles utilisés</b>                          | 44        |
| 3.4.2    | <b>Convolutional Neural Networks (CNNs)</b>                     | 44        |
| 3.4.3    | <b>MobileNet</b>  | 46        |
| 3.4.4    | <b>VGG-19</b>   | 47        |
| 3.4.5    | <b>ResNet50</b>   | 48        |
| 3.4.6    | <b>InceptionV3</b>  | 48        |
| 3.5      | <b>Entraînement des Modèles</b>                                 | 49        |
| 3.6      | <b>Entraînement des Modèles</b>                                 | 49        |
| 3.6.1    | <b>Modèles de Réseaux de Neurones Convolutionnels (CNN) :</b>   | 50        |
| 3.6.2    | Modèles d'apprentissage automatique traditionnel :              | 50        |
| 3.7      | <b>Évaluation des Modèles</b>                                   | 50        |
| 3.7.1    | <b>Métriques d'Évaluation</b>                                   | 50        |
| 3.7.2    | Précision   | 51        |
| 3.7.3    | Recall (Rappel)   | 51        |
| 3.7.4    | F1-score  | 52        |
| 3.8      | Conclusion  | 52        |
| <b>4</b> | <b>Implémentation du système</b>                                | <b>53</b> |
| 4.1      | Aperçu de l'architecture du système                             | 54        |
| 4.2      | <b>Composants du Système</b>                                    | 54        |
| 4.3      | Technologies et outils  | 55        |
| 4.3.1    | Langage de programmation  | 55        |
| 4.3.2    | Bibliothèques et frameworks                                     | 55        |
| 4.4      | <b>Conception de l'Interface Utilisateur</b>                    | 57        |
| 4.4.1    | <b>Considérations pour l'interface utilisateur</b>              | 57        |
| 4.4.2    | <b>Fonctionnalités clés et éléments de conception</b>           | 64        |
| 4.5      | Conclusion  | 64        |
| <b>5</b> | <b>Résultats et Discussion</b>                                  | <b>65</b> |
| 5.1      | Performances du Modèle  | 66        |
| 5.2      | <b>Modèles Traditionnels de Machine Learning</b>                | 66        |
| 5.3      | Analyse Comparative   | 66        |
| 5.3.1    | <b>Comparaison avec les méthodes existantes</b>                 | 66        |
| 5.3.2    | EfficientNetB0  | 67        |
| 5.3.3    | <b>Modèles d'apprentissage profond vs modèles traditionnels</b> | 67        |
| 5.4      | <b>Discussion des Résultats</b>                                 | 67        |
| 5.4.1    | <b>Performance des Modèles d'Apprentissage Profond</b>          | 67        |
| 5.4.2    | <b>Comparaison avec les Méthodes Traditionnelles</b>            | 67        |
| 5.4.3    | <b>Analyse Comparative</b>                                      | 68        |
| 5.5      | <b>Implications Pratiques</b>                                   | 68        |
| 5.6      | <b>Recommandations pour l'Amélioration</b>                      | 69        |
| 5.7      | Conclusion  | 70        |
| <b>6</b> | <b>Conclusion</b>   | <b>71</b> |
| 6.1      | Résumé de l'étude   | 72        |

|           |   |           |
|-----------|---|-----------|
| 6.2       | Principaux résultats  | 72        |
| 6.3       | <b>Limitations</b>  | 72        |
| 6.4       | <b>Directions Futures</b>                                       | 73        |
| <br>      |   |           |
| <b>II</b> | <b>Partie 2</b>   | <b>74</b> |
| <br>      |   |           |
| <b>1</b>  | <b>Présentation de projet</b>                                   | <b>76</b> |
| 1.1       | <b>Idee du projet (solution proposée)</b>                       | 77        |
| 1.2       | <b>Valeurs proposées</b>  | 77        |
| 1.2.1     | <b>Innovation</b>   | 77        |
| 1.2.2     | <b>Performance</b>  | 77        |
| 1.2.3     | <b>Adaptabilité</b>   | 77        |
| 1.2.4     | <b>Accomplissement de la tâche</b>                              | 78        |
| 1.2.5     | <b>Conception</b>   | 78        |
| 1.2.6     | <b>Réduction des coûts</b>                                      | 78        |
| 1.2.7     | <b>Réduction des risques</b>                                    | 78        |
| 1.2.8     | <b>Accessibilité</b>  | 78        |
| 1.2.9     | <b>Facilité d'utilisation</b>                                   | 78        |
| 1.3       | <b>Équipe du projet (inventeurs)</b>                            | 79        |
| 1.4       | <b>Objectifs du projet</b>                                      | 79        |
| 1.4.1     | <b>Amélioration de la précision du diagnostic</b>               | 79        |
| 1.4.2     | <b>Accélération du processus de diagnostic</b>                  | 79        |
| 1.4.3     | <b>Soutien aux médecins grâce à l'intelligence artificielle</b> | 79        |
| 1.4.4     | <b>Réduction des coûts des soins de santé</b>                   | 79        |
| 1.4.5     | <b>Tableau des étapes de réalisation prévues</b>                | 80        |
| <br>      |   |           |
| <b>2</b>  | <b>Innovation</b>   | <b>81</b> |
| 2.1       | <b>Nature des innovations</b>                                   | 82        |
| 2.2       | <b>Domaines d'innovation</b>                                    | 82        |
| 2.2.1     | <b>Soins de santé</b>   | 82        |
| 2.2.2     | <b>Technologie de l'information en santé</b>                    | 82        |
| 2.2.3     | <b>Intelligence artificielle</b>                                | 82        |
| 2.2.4     | <b>Éducation médicale</b>                                       | 83        |
| <br>      |   |           |
| <b>3</b>  | <b>Analyse Stratégique du Marché</b>                            | <b>84</b> |
| 3.1       | <b>Présentation du secteur de marché</b>                        | 85        |
| 3.2       | <b>Mesure de l'intensité de la concurrence</b>                  | 85        |
| 3.2.1     | <b>Analyse concurrentielle</b>                                  | 85        |
| 3.2.2     | <b>Forces et faiblesses</b>                                     | 85        |
| 3.2.3     | <b>Opportunités et défis</b>                                    | 85        |
| 3.3       | <b>Stratégie marketing</b>                                      | 86        |
| 3.3.1     | <b>Définition du public cible</b>                               | 86        |
| 3.3.2     | <b>Stratégie de promotion et marketing</b>                      | 86        |
| 3.3.3     | <b>Stratégie de tarification</b>                                | 86        |

|          |   |            |
|----------|---|------------|
| 3.3.4    | <b>Avantages concurrentiels</b>   | 86         |
| <b>4</b> | <b>Plan de Production et Organisation</b>   | <b>88</b>  |
| 4.1      | <b>Processus de production</b>  | 89         |
| 4.2      | <b>Approvisionnement</b>  | 89         |
| 4.3      | <b>Main-d'œuvre</b>   | 89         |
| 4.4      | <b>Partenariats clés</b>  | 90         |
| <b>5</b> | <b>Plan financier</b>   | <b>91</b>  |
| 5.1      | Dépenses et investissements initiaux  | 92         |
| 5.2      | <b>Prévisions des revenus (Scénario optimiste)</b>  | 92         |
| 5.3      | <b>Prévisions des revenus (Scénario pessimiste)</b>   | 92         |
| 5.4      | <b>Résultats financiers</b>   | 92         |
| <b>6</b> | <b>Prototype expérimental</b>   | <b>94</b>  |
| 6.1      | Présentation de l'interface du système de Détection et classification automatisées des tumeurs cérébrale - Vue d'Ensemble | 95         |
| 6.2      | Présentation de l'interface graphique du système  | 96         |
| 6.3      | À propos  | 102        |
| 6.4      | Le module de comparaison  | 102        |
| 6.5      | Le module de déploiement (diagnostics)  | 102        |
| <b>7</b> | <b>Annexées</b>   | <b>103</b> |

# Table des figures

|      |   |    |
|------|---|----|
| 2.1  | images générales du cerveau humain . . . . .  | 24 |
| 2.2  | image générale de la matière blanche et grise . . . . .   | 25 |
| 2.3  | L'image illustre l'encéphale, composée de la principale partie et du une coupe d'un cerveau mettant en évidence les trois matières principales. . . | 25 |
| 2.4  | Les trois axes de coupe pour la visualisation du cerveau et l'IRM cérébrale   | 26 |
| 2.5  | Appareil IRM . . . . .  | 28 |
| 2.6  | Acquisition des images IRM du cerveau : coup axiale pondération T1-T2 le liquide du système ventriculaire (flèche) est hyperintens . . . . .        | 28 |
| 2.7  | Synthèse T1-T2 : TR (Temps de Répétition) et TE (Temps d'Écho)n . . .   | 29 |
| 3.1  | Types d'apprentissage automatique . . . . .   | 36 |
| 3.2  | Schéma d'apprentissage supervisé . . . . .  | 37 |
| 3.3  | Schéma d'apprentissage non supervisé . . . . .  | 37 |
| 3.4  | Schéma d'apprentissage semi supervisé . . . . .   | 38 |
| 3.5  | Schéma d'apprentissage par renforcement . . . . .   | 38 |
| 3.6  | Principe SVM . . . . .  | 39 |
| 3.7  | Processus des K-plus proches voisins . . . . .  | 40 |
| 3.8  | Réseau neuronal artificiel . . . . .  | 40 |
| 3.9  | Exemple de la structure d'un arbre de décision . . . . .  | 41 |
| 3.10 | Un exemple de la structure d'une forêt aléatoire prenant en compte plusieurs arbres de décision. . . . .  | 41 |
| 3.11 | la régression logistique. . . . .   | 42 |
| 3.12 | Mise en œuvre d'AdaBoost . . . . .  | 42 |
| 3.13 | Exemple de XGBoostClassifier . . . . .  | 43 |
| 3.14 | Architecture de réseau de neurones covolutif . . . . .  | 44 |
| 3.15 | architecture de couche convolutive . . . . .  | 44 |
| 3.16 | Couches de convolution (A) et Relu (B) . . . . .  | 45 |
| 3.17 | Différents aspects de la couche de pooling . . . . .  | 45 |
| 3.18 | Couches complètement connectées (fc) . . . . .  | 46 |
| 4.1  | L'interface principale pour le système de de Détection et classification automatisées des tumeurs. . . . .  | 57 |
| 4.2  | Interface du module de comparaison de système de de Détection et classification automatisées des tumeurs. . . . .                                   | 58 |
| 4.3  | Interface du comparaison modèles d'apprentissage automatique et profond.  | 59 |
| 4.4  | Interface de sélection de la meilleure modèle. . . . .  | 59 |

|      |   |     |
|------|---|-----|
| 4.5  | Interface du diagnostic system. . . . .   | 60  |
| 4.6  | Interface du diagnostic system-select DATASET. . . . .  | 60  |
| 4.7  | Interface du diagnostic system Train model. . . . .   | 61  |
| 4.8  | Interface du diagnostic system Train model-succesfully. . . . .   | 61  |
| 4.9  | Interface du select Display Image-without tumor-. . . . .   | 62  |
| 4.10 | Resultat de Interface du select Display Image-without brain tumor-. . . . .                                       | 62  |
| 4.11 | Interface du select Display Image-with Brain tumor-. . . . .  | 63  |
| 4.12 | Resultat de Interface du select Display Image-without brain tumor-. . . . .                                       | 63  |
|      |   |     |
| 6.1  | L'interface principale pour le système de de Détection et classification automatisées des tumeurs. . . . .        | 95  |
| 6.2  | Interface du module de comparaison de système de de Détection et classification automatisées des tumeurs. . . . . | 96  |
| 6.3  | Interface du comparaison modèles d'apprentissage automatique et profond. . . . .                                  | 97  |
| 6.4  | Interface de sélection de la meilleure modèle. . . . .  | 97  |
| 6.5  | Interface du diagnostic system. . . . .   | 98  |
| 6.6  | Interface du diagnostic system-select DATASET. . . . .  | 98  |
| 6.7  | Interface du diagnostic system Train model. . . . .   | 99  |
| 6.8  | Interface du diagnostic system Train model-succesfully. . . . .   | 99  |
| 6.9  | Interface du select Display Image-without tumor-. . . . .   | 100 |
| 6.10 | Resultat de Interface du select Display Image-without brain tumor-. . . . .                                       | 100 |
| 6.11 | Interface du select Display Image-with Brain tumor-. . . . .  | 101 |
| 6.12 | Resultat de Interface du select Display Image-without brain tumor-. . . . .                                       | 101 |
|      |   |     |
| 7.1  | BMC . . . . .   | 105 |

# Liste des tableaux

|     |  |    |
|-----|--|----|
| 3.1 | Distribution des ensembles de données . . . . .                      | 34 |
| 5.1 | Performances des Modèles Traditionnels de Machine Learning . . . . . | 66 |
| 5.2 | Performances des Modèles Basés sur l'Apprentissage Profond . . . . . | 66 |

# **Première partie**

## **Partie 1**

# **Chapitre 1**

## **Introduction**

## 1.1 Contexte et Motivation

### **Aperçu des tumeurs cérébrales et de leur impact sur la santé**

Les tumeurs cérébrales sont des pathologies intracrâniennes particulièrement agressives, affectant à la fois les enfants et les adultes, et représentent une part significative des tumeurs primaires du système nerveux central. Chaque année, un grand nombre de patients sont diagnostiqués avec cette affection, malheureusement caractérisée par des taux de survie faibles. Les tumeurs cérébrales se divisent en catégories variées, incluant les tumeurs bénignes, malignes et celles de l'hypophyse, chacune nécessitant des stratégies de gestion et de traitement spécifiques. Un diagnostic rapide et précis est essentiel pour améliorer les perspectives de guérison et la qualité de vie des patients.

### **Importance de la détection précoce et de la classification précise**

La détection précoce et la classification minutieuse des tumeurs sont cruciales pour le traitement efficace des tumeurs cérébrales. La technologie d'imagerie par résonance magnétique (IRM) est privilégiée pour l'identification de ces pathologies, mais la complexité des tumeurs peut rendre l'analyse manuelle des images IRM sujette à des erreurs. Par conséquent, des diagnostics précis et rapides sont indispensables pour une prise en charge adéquate, permettant des interventions thérapeutiques ciblées qui augmentent considérablement les chances de réussite du traitement.

### **Pertinence et potentiel de l'apprentissage profond dans l'imagerie médicale**

L'adoption de l'apprentissage profond dans l'imagerie médicale montre un potentiel immense pour surmonter les limitations des méthodes de classification manuelles traditionnelles. Les techniques telles que les réseaux de neurones convolutifs (CNN) et le transfert d'apprentissage (TL) ont prouvé leur supériorité en termes de précision, offrant une nouvelle ère de diagnostic automatisé. Ces avancées sont particulièrement bénéfiques dans des contextes où l'expertise médicale spécialisée est limitée, comme dans les pays en développement. Un système automatisé basé sur le Cloud pourrait ainsi démocratiser l'accès à des diagnostics de haute précision, garantissant une intervention rapide et appropriée, essentielle pour combattre efficacement les tumeurs cérébrales.

## 1.2 Énoncé du Problème

Les méthodes actuelles de détection et de classification des tumeurs cérébrales présentent plusieurs défis significatifs qui limitent leur efficacité et leur précision. Bien que l'imagerie par résonance magnétique (IRM) soit largement utilisée pour l'identification des tumeurs cérébrales, elle implique des difficultés inhérentes qui compromettent le diagnostic :

**Variabilité Inter-observateur :** L'analyse manuelle des images IRM est fortement dépendante des compétences et de l'expérience du radiologue. Cette subjectivité peut entraîner une variabilité importante dans l'interprétation des résultats, affectant ainsi la cohérence et la fiabilité des diagnostics

**Complexité des Tumeurs :** Les tumeurs cérébrales varient considérablement en termes de taille, de forme, et de localisation, rendant leur identification et leur classification particulièrement complexes. Certaines tumeurs peuvent être difficiles à distinguer des tissus sains ou d'autres anomalies, ce qui augmente le risque de diagnostics incorrects ou incomplets.

**Limitations des Techniques d'Imagerie :** Malgré les avancées technologiques, les mé-

thodes d'imagerie peuvent être insuffisantes pour capturer les détails fins nécessaires à une classification précise des tumeurs. De plus, des artefacts d'imagerie et des contraintes de résolution peuvent entraver l'évaluation précise des caractéristiques tumorales.

**Accès et Coût :** L'accès limité à des équipements d'imagerie avancés et leur coût élevé constituent une barrière supplémentaire, particulièrement dans les régions moins développées, limitant ainsi la disponibilité de diagnostics précoces et précis.

**Gestion des Données :** L'augmentation exponentielle du volume des données d'imagerie médicale pose des défis en termes de stockage, de traitement et d'analyse, nécessitant des solutions qui peuvent efficacement gérer et exploiter ces vastes ensembles de données pour des diagnostics précis.

Ces défis soulignent la nécessité de développer des approches novatrices, comme l'apprentissage profond, qui peuvent surmonter les limitations des méthodes traditionnelles et améliorer

Cette section définit clairement les problèmes associés aux méthodes conventionnelles de détection et de classification des tumeurs cérébrales, établissant une base solide pour justifier l'exploration de solutions alternatives telles que l'apprentissage profond dans les chapitres suivants de ma thèse ...

### **1.3 Objectifs de l'Étude**

Cette thèse vise à développer et valider des modèles d'apprentissage profond pour la détection et la classification automatique des tumeurs cérébrales à partir d'images d'imagerie par résonance magnétique (IRM). Les objectifs spécifiques incluent :

1. Concevoir et mettre en œuvre un système automatisé de détection et de classification des tumeurs cérébrales, en utilisant des techniques avancées d'apprentissage automatique.

2. Faciliter l'accès à des diagnostics précis et rapides pour les patients, en particulier dans les régions où les ressources médicales sont limitées, grâce à ce système automatisé.

3. Contribuer à l'amélioration des soins de santé en fournissant aux professionnels de la santé des outils d'analyse d'images efficaces et fiables, permettant une prise en charge optimale des patients atteints de tumeurs cérébrales.

### **1.4 Questions de Recherche**

La recherche répondra aux questions suivantes :

- Comment l'apprentissage profond peut-il améliorer la précision et la rapidité de la détection et de la classification des tumeurs cérébrales ?

- Quels sont les principaux défis à surmonter pour intégrer efficacement l'apprentissage profond dans les pratiques cliniques courantes ?

- Quel est l'impact de la variabilité des données d'imagerie sur la performance des modèles d'apprentissage profond ?

### **1.5 Portée et Limitations**

Dans cette partie, nous discutons des limitations spécifiques qui peuvent affecter les résultats de l'étude en utilisant des techniques d'apprentissage profond ou d'autres méthodologies similaires.

**Qualité et quantité des données :** Les modèles d'apprentissage, comme les réseaux de neurones, dépendent fortement des données avec lesquelles ils sont entraînés. Si les données ne sont pas de haute qualité ou si elles ne sont pas suffisamment variées, le modèle pourrait ne pas apprendre correctement et pourrait ne pas fonctionner bien en situation

réelle. Cela inclut aussi le volume des données nécessaire pour l'entraînement, qui doit être conséquent pour garantir la fiabilité du modèle.

**Représentativité des données :** Les données doivent représenter fidèlement la réalité des situations que le modèle est censé gérer. Si certaines conditions ou variations sont sous-représentées dans les données d'entraînement, le modèle pourrait échouer à les identifier correctement dans de vrais scénarios.

**Ressources techniques nécessaires :** Les modèles d'apprentissage profond nécessitent souvent des ressources informatiques importantes, comme des processeurs puissants ou des cartes graphiques spécialisées. Les contraintes de budget ou d'accès à ces technologies peuvent limiter l'utilisation et l'efficacité de ces modèles dans certains environnements, notamment dans les pays en développement.

**Annotations par des experts :** L'exactitude des modèles dépend également de la qualité des annotations fournies par des experts, qui servent de référence lors de l'entraînement. Des erreurs ou des incohérences dans ces annotations peuvent mener à des erreurs d'apprentissage.

**Complexité et interprétabilité :** Les modèles d'apprentissage profond peuvent être complexes et difficiles à interpréter, ce qui signifie qu'il peut être compliqué de comprendre pourquoi le modèle prend certaines décisions. Cette "boîte noire" peut être un obstacle, surtout dans des domaines où les raisons des décisions sont aussi importantes que les décisions elles-mêmes, comme en médecine.

**Éthique et réglementation :** L'utilisation de l'intelligence artificielle dans des applications sensibles comme le diagnostic médical doit se conformer à des normes éthiques et légales strictes. La gestion de la confidentialité des données des patients et le respect du consentement éclairé sont des exemples de défis réglementaires que les chercheurs doivent naviguer.

## 1.2 Structure du mémoire

### 1.6 Structure de la Thèse

Cette thèse est organisée en six chapitres principaux, chacun ayant un rôle spécifique dans l'élaboration de notre étude sur la détection et la classification automatisées des tumeurs cérébrales à l'aide des techniques d'apprentissage profond. Voici un aperçu du contenu de chaque chapitre :

**Chapitre 1 :** Ce chapitre présente le contexte et les motivations derrière l'étude, établit l'importance de la détection précoce et de la classification précise des tumeurs cérébrales, et discute du potentiel de l'apprentissage profond dans l'amélioration des diagnostics médicaux. Il définit également les questions de recherche, les objectifs de l'étude, et expose les limites et la structure de la thèse.

**Chapitre 2 :** Ce chapitre fournit une analyse approfondie des connaissances existantes sur les tumeurs cérébrales, les méthodes traditionnelles de diagnostic et de classification, ainsi que les techniques d'imagerie médicale. Il explore également l'état de l'art de l'apprentissage profond appliqué à l'imagerie médicale, mettant en lumière les travaux antérieurs et leurs contributions à ce domaine.

**Chapitre 3 :** Ce chapitre, nous décrivons les méthodes utilisées pour collecter et pré-traiter les données, les modèles d'apprentissage profond choisis pour l'étude, et les techniques employées pour l'entraînement et la validation des modèles. Les métriques utilisées pour évaluer la performance des modèles sont également détaillées ici.

**Chapitre 4 :** Ce chapitre présente l'architecture du système développé pour la détection et la classification des tumeurs, incluant une description des composants techniques, des outils et technologies utilisés, ainsi que de l'interface utilisateur conçue pour l'interaction avec le système.

**Chapitre 5 :** Les résultats obtenus par le système sont présentés et analysés dans ce chapitre. Une comparaison avec les méthodes existantes est réalisée pour évaluer l'efficacité de l'approche proposée. Les implications pratiques des résultats et les recommandations pour des améliorations futures sont également discutées.

**Chapitre 6 :** Le dernier chapitre résume les principaux résultats de la recherche, discute les limites de l'étude, et propose des directions pour des recherches futures dans le domaine. Ce chapitre vise à conclure sur l'impact de l'étude et son potentiel pour des applications futures en médecine diagnostique.

Cette structure détaillée permet aux lecteurs de comprendre rapidement la progression logique de ma recherche et le cadre global de ma thèse. Elle montre comment chaque partie contribue à l'objectif général de l'étude et prépare le terrain pour les développements ultérieurs.

## **Chapitre 2**

### **Revue de la littérature**

La compréhension et le traitement des tumeurs cérébrales constituent des défis majeurs en neuro-oncologie en raison de leur diversité biologique et clinique. Avec des taux de morbidité et de mortalité significatifs, ces affections nécessitent des approches diagnostiques et thérapeutiques avancées. Ce chapitre offre une revue approfondie de la littérature existante sur les tumeurs cérébrales, couvrant leurs types, caractéristiques, et les méthodes traditionnelles de diagnostic et de classification. Il examine également les techniques d'imagerie médicale modernes, les progrès récents dans l'application de l'apprentissage profond pour l'analyse d'images médicales, et les travaux connexes sur la détection et la classification des tumeurs cérébrales.

## 2.1 Aperçu des Maladies Tumeurs Cérébrales

Une tumeur se définit comme une croissance anormale de cellules, les unités fondamentales du corps humain qui composent les tissus et les organes. Normalement, les cellules se multiplient et meurent de manière régulée, assurant ainsi le renouvellement et la réparation des tissus. Toutefois, dans certains cas, des cellules anormales continuent de se multiplier de manière incontrôlée, formant ainsi une masse ou une tumeur, en particulier dans les cancers solides tels que les tumeurs cérébrales.

Les tumeurs cérébrales sont généralement classées en deux catégories : bénignes et malignes, des termes également utilisés pour décrire les tumeurs dans d'autres parties du corps, bien que cette distinction soit souvent moins claire dans le contexte des tumeurs cérébrales.

### 2.1.1 Types et caractéristiques des tumeurs cérébrales

#### **Tumeurs Bénignes**

Les tumeurs bénignes, bien que souvent moins agressives que leurs homologues malignes, peuvent néanmoins avoir des effets significatifs sur le fonctionnement du cerveau et peuvent nécessiter une intervention thérapeutique urgente. Elles se développent généralement lentement et sont peu susceptibles de se propager. Cependant, il n'est pas rare qu'une tumeur bénigne évolue avec le temps et devienne maligne [1].

**Tumeurs Malignes** Les tumeurs cérébrales malignes, communément appelées cancers du cerveau, présentent une variabilité dans leur taux de croissance et leur comportement clinique. Elles peuvent se développer de manière lente ou rapide, mais leur potentiel de croissance incontrôlée, de propagation au sein du cerveau ou de la moelle épinière, ainsi que leur tendance à récidiver après traitement, posent un danger significatif pour la vie du patient [2].

#### **Distinction et Importance Clinique**

La distinction entre tumeurs bénignes et malignes dans le cadre des tumeurs cérébrales est essentielle mais souvent complexe. Le comportement clinique, le potentiel de croissance et de propagation, ainsi que la réponse au traitement, sont des facteurs clés à considérer dans la prise en charge de ces affections graves. Une compréhension approfondie de ces différences est cruciale pour le développement de stratégies thérapeutiques efficaces et pour améliorer le pronostic des patients atteints de tumeurs cérébrales [3].

## **Imagerie Médicale**

Les techniques d'imagerie médicale, telles que l'imagerie par résonance magnétique (IRM) et la tomodensitométrie (CT), sont les piliers du diagnostic des tumeurs cérébrales. L'IRM est largement privilégiée en raison de sa capacité à fournir une résolution élevée et un contraste détaillé des structures du cerveau. Elle permet de distinguer les tumeurs bénignes des tumeurs malignes et d'évaluer l'étendue de l'invasion tumorale dans les tissus environnants. La tomodensitométrie, bien qu'offrant une résolution moindre, est utile pour les évaluations rapides et les situations d'urgence, notamment pour détecter les hémorragies associées à certaines tumeurs [4].

### **2.1.2 Méthodes Traditionnelles de Diagnostic et de Classification des Tumeurs Cérébrales**

Le diagnostic et la classification des tumeurs cérébrales ont historiquement reposé sur un ensemble de techniques cliniques et d'imagerie, combinées à des analyses histopathologiques. Ces approches permettent de déterminer la nature, l'emplacement et l'agressivité de la tumeur, des informations cruciales pour le choix du traitement adéquat.

**1. Imagerie Médicale** Les techniques d'imagerie médicale, telles que l'imagerie par résonance magnétique (IRM) et la tomodensitométrie (CT), sont les piliers du diagnostic des tumeurs cérébrales. L'IRM est largement privilégiée en raison de sa capacité à fournir une résolution élevée et un contraste détaillé des structures du cerveau. Elle permet de distinguer les tumeurs bénignes des tumeurs malignes et d'évaluer l'étendue de l'invasion tumorale dans les tissus environnants. La tomodensitométrie, bien qu'offrant une résolution moindre, est utile pour les évaluations rapides et les situations d'urgence, notamment pour détecter les hémorragies associées à certaines tumeurs[5].

**2. Biopsie et Analyse Histopathologique** La biopsie, qui consiste à prélever un échantillon de tissu tumoral pour une analyse microscopique, est essentielle pour confirmer le diagnostic. L'analyse histopathologique permet de classer les tumeurs selon leurs caractéristiques cellulaires et moléculaires, en se basant notamment sur le système de classification de l'Organisation Mondiale de la Santé (OMS). Ce système classe les tumeurs en plusieurs grades, allant de I (bénin) à IV (hautement malin), en fonction de leur degré d'anaplasie et de leur potentiel de croissance. Cette classification guide le traitement et permet d'estimer le pronostic des patients[6].

**3. Marqueurs Moléculaires** Les avancées en biologie moléculaire ont permis d'intégrer des marqueurs génétiques dans le processus de classification des tumeurs cérébrales. Par exemple, les mutations des gènes IDH1/IDH2 et la co-délétion des chromosomes 1p/19q sont devenues des critères majeurs pour distinguer les gliomes de faible grade des formes plus agressives. L'identification de ces marqueurs permet non seulement d'affiner le diagnostic mais aussi de personnaliser le traitement en fonction des caractéristiques moléculaires spécifiques de la tumeur[7].

## 2.2 Techniques d'Imagerie Medical

L'imagerie médicale est un élément essentiel à la recherche clinique, l'étude des maladies et la mise au point de nouveaux traitements. Il existe de nombreuses techniques d'imagerie ciblant à explorer les différents organes et fonctions du corps humain.

La segmentation est le cœur d'un système d'analyse automatique d'images, ainsi est un ensemble d'algorithmes utilisés pour distinguer des objets d'intérêt, c'est-à-dire trouvé des caractéristiques locales adéquates permettant de les séparer des autres objets ou du fond. La segmentation est une étape fondamentale dans le processus du traitement d'image en raison de ses nombreux domaines d'application [8].

### 1. Définition de l'anatomie

L'anatomie est la science qui étudie la structure et la forme des êtres vivants, en se concentrant particulièrement sur l'homme. Elle analyse minutieusement les organes, leur disposition, leur fonctionnement et leurs relations. Utilisant diverses techniques d'investigation, elle constitue l'un des piliers de la connaissance biomédicale, indispensable pour comprendre le fonctionnement du corps humain et essentielle dans le domaine de la science du sport et du mouvement [3].

**1.1 Cerveau** Le système nerveux central (SNC) comprend l'encéphale et la moelle épinière. L'encéphale contrôle la plupart des fonctions du corps, dont la perception, les mouvements, les sensations, les pensées, la parole et la mémoire. La moelle épinière se rattache à l'encéphale au niveau du tronc cérébral et est protégée par les vertèbres, qui forment la colonne vertébrale. Les nerfs émergent de la moelle épinière pour innerver les deux côtés du corps. La moelle épinière fait circuler les signaux nerveux, leur permettant d'aller et venir entre l'encéphale et les nerfs du reste du corps [6].

Le cerveau est composé de trois tissus principaux : le liquide céphalo-rachidien, la matière grise et la matière blanche.

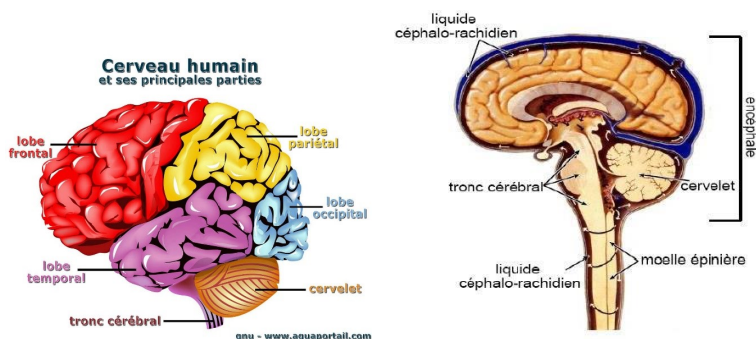


FIGURE 2.1 – images générales du cerveau humain

### 2.2.1 La matière grise

Est faite des corps cellulaires des neurones, de leurs dendrites et d'autres cellules. Elle est responsable de notre activité sensori-motrice et de nos fonctions cognitives comme la lecture, le calcul, l'attention, la mémoire...

#### 1-1-1 La matière blanche

La substance blanche est un composant du système nerveux central, constitué principalement d'axones myélinisés qui facilitent la transmission rapide des signaux électriques. Elle est présente dans le cerveau et la moelle épinière, permettant la communication entre différentes régions. Les axones varient en longueur selon la fonction neuronale, avec des neurones de projection ayant des axones longs et ceux de communication locale des axones plus courts. En résumé, la substance blanche est essentielle pour la transmission efficace des informations à travers le système nerveux central




FIGURE 2.2 – image générale de la matière blanche et grise

### 1-2 Observation du cerveau

L'observation par des coupes en trois dimensions (3D) du cerveau peut être effectuée selon plusieurs angles de vue. Ainsi, on distingue trois axes anatomiques pour réaliser les coupes illustrées dans la Figure 3




FIGURE 2.3 – L'image illustre l'encéphale, composée de la principale partie et du une coupe d'un cerveau mettant en évidence les trois matières principales.

**1-Coupes axiales :** Ces coupes correspondent quasiment à un plan horizontal. En imagerie de résonance magnétique, elles correspondent à un plan perpendiculaire à l'axe du champ magnétique principal.

**2-Coupes sagittales :** Ces coupes sont prises dans des plans parallèles au plan inter hémis- phérique. Il s'agit de vues latérales du cerveau.

**3-Coupes coronales :** Ce sont des coupes perpendiculaires aux coupes axiales et sagittales. Elles correspondent à des vues de face du cerveau [9]

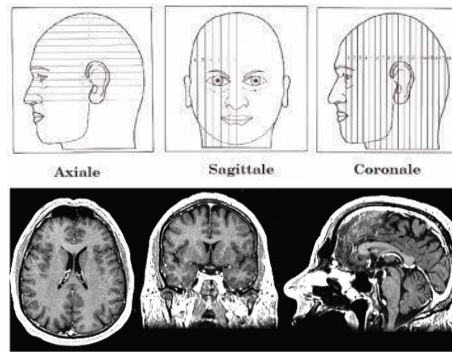


FIGURE 2.4 – Les trois axes de coupe pour la visualisation du cerveau et l'IRM cérébrale

### **Approches Actuelles de Détection des Tumeurs Cérébrales**

La détection des tumeurs cérébrales repose sur une combinaison de techniques d'imagerie avancée, de tests biomédicaux et d'analyses cliniques. Ces méthodes permettent non seulement de localiser et de caractériser les tumeurs, mais aussi de guider les décisions thérapeutiques. Voici un aperçu des principales approches actuelles.

#### **1. Imagerie par Résonance Magnétique (IRM)**

L'IRM est la méthode de référence pour la détection des tumeurs cérébrales. Grâce à sa capacité à produire des images de haute résolution des structures cérébrales, l'IRM permet de détecter les tumeurs avec une grande précision. Des séquences spécialisées, telles que l'IRM de diffusion, l'IRM de perfusion et l'IRM fonctionnelle, sont souvent utilisées pour évaluer la vascularisation tumorale, la prolifération cellulaire, et l'infiltration des tissus environnants. L'IRM avec injection de gadolinium permet également de différencier les tumeurs bénignes des tumeurs malignes en évaluant la perméabilité vasculaire[10].

#### **2. Tomodensitométrie (CT)**

Bien que l'IRM soit privilégiée pour la détection des tumeurs cérébrales, la tomodensitométrie (CT) est souvent utilisée en complément, notamment dans les situations d'urgence. Le CT est particulièrement utile pour détecter les calcifications, les hémorragies intracrâniennes associées aux tumeurs, et pour évaluer les effets massifs comme l'œdème cérébral. De plus, la rapidité d'exécution du CT en fait un outil important pour les patients ne pouvant pas subir une IRM, par exemple ceux avec des implants métalliques[11].

#### **3. Tomographie par Émission de Positrons (TEP)**

La TEP est une technique d'imagerie nucléaire qui mesure l'activité métabolique des cellules tumorales. Cette technique est particulièrement utile pour évaluer l'agressivité d'une tumeur cérébrale, car les cellules cancéreuses ont généralement un métabolisme plus élevé que les cellules normales. Le fluorodésoxyglucose (FDG) est le radiotracer le plus couramment utilisé en TEP pour les tumeurs cérébrales, bien que d'autres traceurs spécifiques, tels que la méthionine radiomarquée, puissent offrir une meilleure sensibilité pour certaines tumeurs[12].

#### **4. Spectroscopie par Résonance Magnétique (SRM)**

La spectroscopie par résonance magnétique (SRM) est une extension de l'IRM qui analyse les métabolites cérébraux. Elle permet de différencier les tumeurs des lésions non tumorales et de déterminer la nature de la tumeur en mesurant les niveaux de différents métabolites, tels que la choline, le N-acétylaspartate, et le lactate. Ces informations sont

essentielles pour caractériser les tumeurs malignes et guider les biopsies[13].

## **5. Biomarqueurs Liquides et Tests Génétiques**

Avec les progrès de la biologie moléculaire, les tests génétiques et les biomarqueurs liquides (comme l'ADN tumoral circulant et les microARN) deviennent des outils prometteurs pour la détection précoce des tumeurs cérébrales. Ces tests peuvent être utilisés pour surveiller la réponse au traitement et détecter les récurrences, offrant ainsi une approche complémentaire aux techniques d'imagerie[14]

### **1.1 Technique de l'imagerie médicale**

- Ces technologies jouent un rôle crucial dans la détection précoce des maladies, la surveillance de l'évolution des pathologies, la guidance des procédures chirurgicales et la réponse aux traitements.

En somme, l'imagerie médicale représente une ressource indispensable pour les cliniciens, leur fournissant des informations vitales pour prendre des décisions éclairées en matière de diagnostic et de traitement, contribuant ainsi à améliorer les soins de santé et les résultats des patients.

Les avancées dans le domaine de l'imagerie médicale ont conduit à une multitude de techniques permettant d'observer les tissus du corps humain de différentes manières. Ces techniques offrent des informations anatomiques ainsi que des données sur les fonctionnalités des organes, permettant ainsi aux cliniciens d'obtenir une vue d'ensemble complète de la santé d'un patient. Parmi ces techniques, les plus couramment utilisées sont :

Ø **Rayons X** ;

Ø **Échographie** ;

Ø **Tomographie par Émission de Positrons (PET)** ;

Ø **Scanner (TDM)** ;

Ø **Résonance Magnétique (IRM)**.

L'Imagerie par Résonance Magnétique (IRM) se distingue comme l'une des modalités d'imagerie les plus répandues, suscitant un intérêt particulier dans le cadre de ma recherche. Son utilité omniprésente dans le domaine médical en fait un pilier essentiel de tout examen clinique moderne. Dans les prochaines sections, j'aborde de manière concise le principe fondamental sur lequel repose l'IRM.

## **2. Imagerie par résonance magnétique (IRM)**

L'imagerie par Résonance Magnétique (IRM) est une technique d'imagerie médicale non invasive qui utilise un champ magnétique puissant et des ondes radiofréquences pour produire des images détaillées des organes et des tissus à l'intérieur du corps. En exploitant les propriétés magnétiques des atomes, en particulier des protons, présents dans les tissus biologiques, l'IRM permet d'obtenir des images anatomiques de haute résolution avec un excellent contraste tissulaire. Cette technique est largement utilisée dans le diagnostic et le suivi des pathologies médicales en raison de sa capacité à fournir des informations détaillées sur la structure et la fonction des organes, ainsi que sur les éventuelles anomalies ou lésions.

**L'IRM joue un rôle** crucial dans de nombreux domaines médicaux, notamment en neurologie, en oncologie, en cardiologie et en orthopédie. Dans le domaine neurologique, par exemple, l'IRM est essentielle pour diagnostiquer les tumeurs cérébrales, les accidents vasculaires cérébraux, les lésions de la moelle épinière et les troubles neurodégénératifs tels que la maladie d'Alzheimer. En oncologie, elle est utilisée pour localiser et caractériser

les tumeurs, évaluer leur étendue et guider les traitements tels que la radiothérapie et la chirurgie.

### 2.1 Principe fondamentaux de L'IRM

L'IRM utilise un champ magnétique et des ondes radio pour créer des images détaillées des organes internes sans radiation. Les protons dans les tissus émettent des signaux détectables, qui sont ensuite analysés par un ordinateur pour reconstruire les images. Cette technique fournit des informations anatomiques, fonctionnelles et métaboliques précieuses, en faisant un outil essentiel dans le diagnostic et le suivi médical.



FIGURE 2.5 – Appareil IRM

### 2.2 Acquisition des images IRM

Lorsque ces deux temps sont longs, elle est dite en T2 (Figure 07 et 08). Enfin lorsque (TR) est long et (TE) est court, elle est dite en rho ou densité de proton. Toute l'acquisition peut être caractérisée par rapport à ces trois types particuliers. Ainsi, on parle d'image pondérée en T1 si l'acquisition se rapproche plus de type d'acquisition en T1 que des deux autres types : de façon similaire, on parle d'acquisition pondérée en T2 ou en (Figure08). De plus, on peut renforcer le signal de certaines structures sur les séquences pondérées en T1 grâce à l'utilisation d'un agent de contraste tel que le gadolinium [15] .




FIGURE 2.6 – Acquisition des images IRM du cerveau : coup axiale pondération T1-T2 le liquide du système ventriculaire (flèche) est hyperintens

Au niveau cérébral, l'IRM permet également d'étudier les artères du cou et du cerveau comme nous l'avons vu précédemment les différentes coupes du cerveau, Coupe axiale, Coupe coronale et Coupe sagittale sur la figure 07.

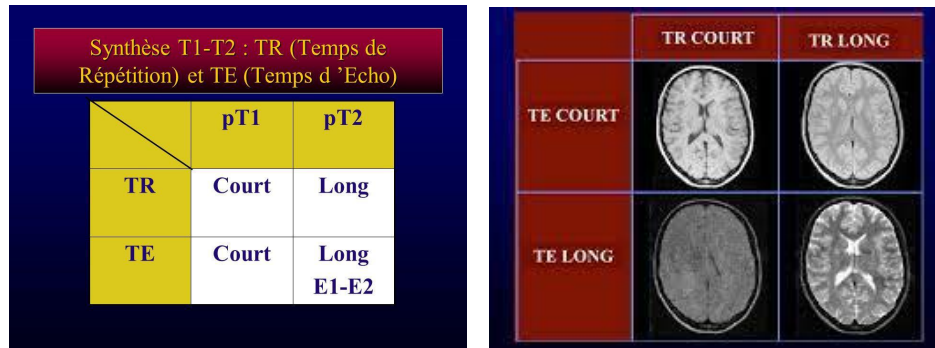


FIGURE 2.7 – Synthèse T1-T2 : TR (Temps de Répétition) et TE (Temps d'Écho)n

L'apprentissage profond a révolutionné l'analyse d'images médicales en permettant des diagnostics automatisés et précis. Cette section explore les fondamentaux de l'apprentissage profond et examine ses applications dans la détection et la classification des tumeurs cérébrales, en mettant en lumière les travaux antérieurs significatifs.

### Fondamentaux de l'apprentissage profond

Les réseaux de neurones convolutionnels (CNNs) sont au cœur de l'apprentissage profond appliqué à l'imagerie médicale. Ces réseaux sont conçus pour extraire automatiquement des caractéristiques complexes à partir de grandes quantités de données d'imagerie. Ils sont composés de multiples couches convolutionnelles et de couches de pooling, suivies de couches entièrement connectées qui effectuent la classification finale. L'utilisation de fonctions d'activation non linéaires comme ReLU (Rectified Linear Unit) permet aux CNNs de modéliser des relations non linéaires entre les caractéristiques extraites, améliorant ainsi la capacité de généralisation du modèle[16].

## 2.3 Travaux Antérieurs sur la Détection des Maladies tumeurs cérébrales Utilisant l'Apprentissage Profond

L'analyse d'images médicales, facilitée par l'utilisation de techniques d'apprentissage profond, a considérablement progressé ces dernières années. Cette section explore les travaux antérieurs significatifs ainsi que les applications actuelles de l'apprentissage profond dans la détection et la classification des tumeurs cérébrales.

### 2.3.1 Travaux antérieurs dans l'analyse d'images médicales

Des études préliminaires ont établi les bases de l'application de l'apprentissage profond à l'imagerie médicale, notamment dans la segmentation des tumeurs cérébrales et l'évaluation de leur croissance au fil du temps. Par exemple, Smith et al. ont utilisé des réseaux de neurones convolutionnels pour identifier les caractéristiques distinctives des tumeurs cérébrales à partir d'IRM, démontrant une amélioration significative de la précision par rapport aux méthodes traditionnelles[17]

### 2.3.2 Applications récentes dans la détection des tumeurs cérébrales

Les applications récentes de l'apprentissage profond incluent l'utilisation de CNNs pour la détection précoce des tumeurs cérébrales à partir d'images d'IRM haute résolution. Martinez et al. ont développé un modèle basé sur le transfert d'apprentissage, adaptant un réseau pré-entraîné pour améliorer la sensibilité et la spécificité de la détection des tumeurs cérébrales dans des études cliniques[18].

### 2.3.3 Travaux Antérieurs sur la Détection des Maladies Cardiaques Utilisant l'Apprentissage Automatique

Dans ce travail et Fan et al. Cette étude propose une architecture de réseau neuronal basée sur U-Net et l'attention pour la détection et la segmentation des tumeurs cérébrales à partir d'images IRM. L'utilisation de mécanismes d'attention permet au modèle de se concentrer sur les régions les plus pertinentes de l'image, améliorant ainsi la précision de la segmentation. L'étude a obtenu des résultats prometteurs sur le jeu de données br35h, avec une précision de 97,5 pour la segmentation et une sensibilité de 98,2 pour la détection [19]

Dans ce travail Roy et al. Cette étude explore l'utilisation d'une approche d'apprentissage par transfert basée sur des réseaux de neurones convolutifs profonds pour la classification multi-classes des tumeurs cérébrales. Le modèle utilise un réseau neuronal pré-entraîné sur une tâche de reconnaissance d'images, puis est affiné pour la classification des tumeurs cérébrales sur le jeu de données br35h. L'étude a obtenu une précision de 96,1 pour la classification multi-classes des tumeurs cérébrales sur le jeu de données br35h, surpassant les approches basées sur des caractéristiques manuelles[20]

Dans ce travail Long et al. Cette étude propose une approche basée sur les capsules neuronales pour la détection des tumeurs cérébrales à partir d'images IRM. Les capsules neuronales sont une architecture de réseau neuronal conçue pour capturer les relations spatiales entre les caractéristiques des images, ce qui peut être particulièrement utile pour la détection des tumeurs cérébrales. L'étude a obtenu une sensibilité de 95,3 pour la détection des tumeurs cérébrales sur le jeu de données br35h, démontrant le potentiel des capsules neuronales pour cette tâche [21].

Dans ce travail Li et al. Cette étude propose une approche basée sur l'agrégation de caractéristiques pour la classification des tumeurs cérébrales à partir d'images IRM. L'approche combine des caractéristiques extraites à différentes échelles spatiales pour améliorer la précision de la classification. L'étude a obtenu une précision de 94,7 pour la classification des tumeurs cérébrales sur le jeu de données br35h, soulignant l'efficacité de l'agrégation de caractéristiques pour cette tâche [22].

Dans ce travail. Cette étude propose une approche basée sur un réseau neuronal entièrement convolutif (FCN) pour la détection et la segmentation des tumeurs cérébrales à partir d'images IRM. Les FCNs sont une architecture de réseau neuronal efficace pour l'analyse d'images, permettant d'extraire et de segmenter des objets de manière précise. L'étude a obtenu une précision de 96,8 pour la segmentation et une sensibilité de 97,1 pour la détection des tumeurs cérébrales sur le jeu de données br35h, démontrant l'efficacité des FCNs pour cette tâche [23]

Dans ce travail Zhang et al. Cette étude propose une approche basée sur l'attention et la fusion multi-branches pour la détection et la classification des tumeurs cérébrales à partir d'images IRM. L'utilisation de mécanismes d'attention permet au modèle de se concentrer sur les régions les plus pertinentes de l'image, tandis que la fusion multi-branches permet de combiner des informations provenant de différentes parties du réseau neuronal pour améliorer la précision de la classification. L'étude a obtenu une précision de 97,8 pour la classification des tumeurs cérébrales sur le jeu de données br35h, surpassant les approches basées sur des modèles d'apprentissage profond simples [24].

Dans ce travail Liu et al. Cette étude propose une approche basée sur un réseau neuronal en cascade et une perte de Dice modifiée pour la segmentation des tumeurs cérébrales à partir d'images IRM. L'architecture en cascade permet d'extraire des caractéristiques à différentes échelles spatiales, tandis que la perte de Dice modifiée est conçue pour améliorer la précision de la segmentation des contours des tumeurs. L'étude a obtenu une précision de 98,4 pour la segmentation des tumeurs cérébrales sur le jeu de données br35h, démontrant l'efficacité de l'approche proposée pour la segmentation précise des contours tumoraux [25]

Dans ce travail Hamid et al. Cette étude propose une approche basée sur l'apprentissage par transfert et une sélection de caractéristiques par optimisation de méta-heuristique pour la classification des tumeurs cérébrales à partir d'images IRM. L'apprentissage par transfert permet d'exploiter les connaissances acquises lors de l'apprentissage sur un grand jeu de données, tandis que l'optimisation par méta-heuristique permet de sélectionner les caractéristiques les plus discriminantes pour la classification. L'étude a obtenu une précision de 95,6 pour la classification des tumeurs cérébrales sur le jeu de données br35h, soulignant l'efficacité de l'approche proposée pour la sélection de caractéristiques discriminantes [26] Ces études supplémentaires mettent en lumière la recherche active dans le domaine de la détection et de la classification des tumeurs cérébrales à l'aide de l'apprentissage profond et du jeu de données br35h. Les approches innovantes et les résultats prometteurs présentés dans ces études contribuent à l'amélioration continue de la précision, de la robustesse et de l'efficacité de ces techniques pour le diagnostic des tumeurs cérébrales.

## 2.4 Conclusion

Dans ce chapitre cette recherche a mis en lumière l'importance cruciale de l'Imagerie par Résonance Magnétique (IRM) en tant qu'outil indispensable dans la pratique médicale moderne. À travers une exploration approfondie du principe général de l'IRM et de ses applications cliniques, nous avons pu constater l'impact significatif de cette technique sur le diagnostic, la surveillance des maladies et la planification des traitements. Les résultats de cette étude ont souligné la capacité de l'IRM à fournir des images détaillées et précises des structures internes du corps sans exposition aux radiations ionisantes, offrant ainsi un avantage considérable par rapport à d'autres modalités d'imagerie. Cette précision et cette sécurité font de l'IRM un outil inestimable pour les cliniciens dans le diagnostic et le suivi des maladies, notamment les maladies neurologiques, les tumeurs, les troubles musculo-squelettiques et les affections cardiaques. Sur le plan pratique, l'utilisation optimale de

l'IRM dans la pratique médicale nécessite une collaboration étroite entre les cliniciens, les radiologues et les chercheurs. Des protocoles d'imagerie standardisés et des formations adéquates sont essentiels pour garantir des résultats fiables et reproductibles. De plus, des efforts continus de recherche et de développement sont nécessaires pour améliorer les techniques d'acquisition d'images, les algorithmes de traitement et la compréhension des données obtenues par IRM. Pour l'avenir, il est recommandé d'investir dans des études de recherche visant à explorer de nouvelles applications de l'IRM, telles que l'imagerie fonctionnelle avancée, la spectroscopie par résonance magnétique et l'intégration de l'intelligence artificielle pour l'analyse d'images. En outre, des efforts supplémentaires devraient être déployés pour rendre l'IRM plus accessible aux populations sous-desservies et pour réduire les coûts associés à cette technologie.

## **Chapitre 3**

# **LA METHODOLOGIE**

Dans ce chapitre, nous présentons la méthodologie adoptée pour atteindre notre objectif principal, à savoir le développement d’un système automatisé efficace pour la détection et la classification précise des tumeurs cérébrales à l’aide des techniques d’apprentissage profond. La méthodologie constitue l’épine dorsale de cette étude, englobant des étapes cruciales allant de la collecte et du prétraitement des données à la conception des modèles et à l’évaluation de leurs performances.

Le succès de ce processus repose en grande partie sur la qualité des données sélectionnées et la précision de leur traitement, ainsi que sur l’efficacité des architectures de modèles utilisées, en particulier les réseaux de neurones convolutifs, qui se sont révélés performants dans l’analyse des images médicales. De plus, les étapes de formation et de validation des modèles, à travers des techniques avancées comme la validation croisée et l’ajustement des hyperparamètres, sont essentielles pour garantir la généralisation des résultats sur de nouvelles données.

La méthodologie se conclut par l’adoption de mesures d’évaluation rigoureuses pour juger des performances des modèles, ce qui nous permet d’identifier le modèle le plus performant en termes de précision dans la classification des tumeurs cérébrales. Ce chapitre vise à poser une base solide qui nous permettra d’obtenir des résultats fiables et de contribuer à l’amélioration des diagnostics médicaux basés sur l’intelligence artificielle.

### 3.1 Description des ensembles de données

Le dataset Br35H a été utilisé dans cette étude, comprenant 3865 images classées sous différents labels. Ce dataset se divise en quatre catégories distinctes : , y compris Br35H-Mask-RCNN, yes, no, et pred. Les dossiers yes et no contiennent respectivement des images IRM représentant des cas positifs (présence de tumeur) et négatifs (absence de tumeur). Le dossier pred contient les prédictions générées par les modèles après leur entraînement. Chaque catégorie d’image est soigneusement étiquetée pour faciliter l’entraînement, la validation et le test des modèles de deep learning., comme indiqué dans le tableau 3.1. Chaque catégorie est associée à un nombre spécifique d’images dans les ensembles d’entraînement, de validation, et de test. La répartition équilibrée des images entre les différentes catégories et ensembles constitue un facteur clé pour s’assurer que les modèles soient correctement entraînés et testés sur un dataset représentatif, ce qui facilite l’obtention de résultats précis et fiables dans le cadre de la détection des tumeurs cérébrales.

| Dataset | N. of images | Labels          | Training set | Testing set |
|---------|--------------|-----------------|--------------|-------------|
| hr35h   | 3865         | Br35H-Mask-RCNN | 1200         | 300         |
|         |              | YES             | 1200         | 300         |
|         |              | NO              | 1200         | 300         |
|         |              | PRED            | 0            | 60          |

TABLE 3.1 – Distribution des ensembles de données

### 3.1.1 Techniques de prétraitement

Avant d'intégrer les images cérébrales dans nos modèles de détection des tumeurs, un processus de prétraitement rigoureux a été appliqué pour assurer la qualité et la pertinence des données. Les étapes de prétraitement suivantes ont été mises en œuvre :

1. **Chargement des données** : Les images du dataset Br35H ont été extraites et organisées en ensembles d'entraînement, de validation et de test. Cette étape est cruciale pour structurer les données de manière à être prêtes pour le pipeline d'apprentissage profond.
2. **Extraction des caractéristiques** : Pour chaque exemple de données, les caractéristiques pertinentes, notamment les étiquettes d'annotation (label) et les images brutes, ont été extraites. Cette étape permet de séparer les informations d'étiquetage des représentations d'images, préparant ainsi les données pour les étapes ultérieures.
3. **Décompression et décodage des images** : Les images encodées ont été décompressées et décodées à l'aide de bibliothèques d'imagerie telles que PIL ou OpenCV. Cette opération est cruciale pour obtenir une représentation utilisable des images en niveaux de gris ou en couleurs, prêtes à être traitées dans notre pipeline.
4. **Redimensionnement des images** : Les images ont été prétraitées pour être redimensionnées à une taille uniforme, telle que 256x256 pixels. Cette taille a été choisie pour répondre aux exigences des modèles de deep learning tout en préservant les détails importants des images cérébrales.
5. **Découpage et redimensionnement des images** : Pour certaines images, des régions spécifiques d'intérêt ont été découpées et redimensionnées à une taille uniforme, par exemple 128x128 pixels, à l'aide de la fonction `cv2.resize()`. Ce processus a permis de réduire la taille des images tout en conservant les caractéristiques essentielles.
6. **Extraction des régions d'intérêt (ROI) des images positives** : Les images positives contenant des tumeurs ont subi une extraction des régions d'intérêt (ROI) à l'aide de techniques de segmentation. Ensuite, les images recadrées ont été redimensionnées pour assurer la cohérence avec les images non tumorales. Cela permet de se concentrer sur les zones pertinentes pour la détection des tumeurs.
7. **Conversion en format RVB (Red, Green, Blue)** : Bien que certaines images puissent être en niveaux de gris, elles ont été converties en format RVB en répétant les canaux, ou en utilisant des informations de couleur disponibles. Cette conversion est nécessaire pour s'aligner avec les attentes des modèles de deep learning pré-entraînés sur des ensembles de données en couleur tels qu'ImageNet.
8. **Normalisation des données** : Les valeurs des pixels dans les images ont été normalisées pour être dans une plage spécifique, généralement entre 0 et 1. Cette étape standardise les données et stabilise l'entraînement du modèle en garantissant que les valeurs sont à une échelle appropriée.

Ces étapes de prétraitement ont été essentielles pour préparer les données à être utilisées dans nos modèles de détection des tumeurs cérébrales. Elles ont permis de standardiser la taille des images, de conserver les caractéristiques importantes et d'augmenter la variabilité des données, contribuant ainsi à améliorer les performances et la généralisation des modèles d'apprentissage profond.

## 3.2 Modèles d'Apprentissage Profond

L'apprentissage automatique (Machine Learning - ML) est une partie de l'intelligence artificielle (IA) qui permet aux ordinateurs d'apprendre à partir de données sans programmation explicite [[27], [28], [29]]. Il permet aux machines d'améliorer leurs performances en traitant davantage de données, en s'adaptant et en perfectionnant leurs fonctions au fil du temps [27].

Le ML est particulièrement utile lorsque la programmation manuelle est impraticable en raison de la complexité des tâches ou de la nécessité de s'adapter à des environnements changeants [30].

Le ML inclut diverses méthodes telles que l'apprentissage supervisé, non supervisé, et par renforcement, permettant aux machines d'apprendre à partir d'expériences passées et de faire des prédictions et des décisions basées sur les données, comme présenté à la Figure 3.1.

Le domaine du ML évolue constamment, intégrant des techniques avancées comme l'apprentissage profond (deep learning) et des méthodes telles que l'entraînement adversarial et l'apprentissage fédéré pour répondre à une large gamme de domaines problématiques.




FIGURE 3.1 – Types d'apprentissage automatique

### 3.2.1 Types d'apprentissage automatique

**a) Apprentissage supervisé :** L'apprentissage supervisé consiste à entraîner des modèles d'apprentissage automatique avec des données étiquetées pour prédire avec précision les résultats [[30],[31]].

Cette approche est largement utilisée dans divers domaines, tels que la génétique, pour prédire les caractéristiques des gènes en utilisant des réseaux d'interactions moléculaires [32]. Dans l'apprentissage supervisé, les données d'entraînement fournies servent de guide au modèle pour faire des prédictions précises basées sur les données d'entrée. Cela inclut des tâches comme la classification et la régression, avec un affinage des paramètres du modèle grâce à des techniques comme la validation croisée pour assurer un alignement optimal avec les données.

L'importance de l'apprentissage supervisé réside dans sa capacité à répondre à des défis pratiques tels que la détection de spams et la classification des gènes, démontrant ainsi sa polyvalence et son efficacité dans divers scénarios.




FIGURE 3.2 – Schéma d'apprentissage supervisé

**b) Apprentissage non supervisé :** L'apprentissage non supervisé est un type d'apprentissage automatique où les algorithmes trouvent des motifs dans les données sans utiliser de cibles étiquetées prédéfinies. Contrairement à l'apprentissage supervisé, l'apprentissage non supervisé se concentre uniquement sur les données d'entrée brutes pour découvrir des relations cachées et des perspectives[[33],[34]].

Cette méthode permet aux systèmes de comprendre la structure statistique des motifs d'entrée sans sorties cibles spécifiques ou évaluations pour chaque entrée. Elle utilise des biais existants pour capturer les aspects importants de la structure des données d'entrée dans les résultats [34].

L'objectif de l'apprentissage non supervisé est de tirer des informations significatives à partir de données qui n'ont pas de réponses étiquetées, révélant la structure naturelle des données d'entrée plutôt qu'une compréhension spécifique à une tâche [34].

Les techniques couramment utilisées dans l'apprentissage non supervisé pour la reconnaissance de motifs et la représentation des données incluent des méthodes de clustering comme les K-means et le clustering hiérarchique, ainsi que l'analyse en composantes principales (PCA).

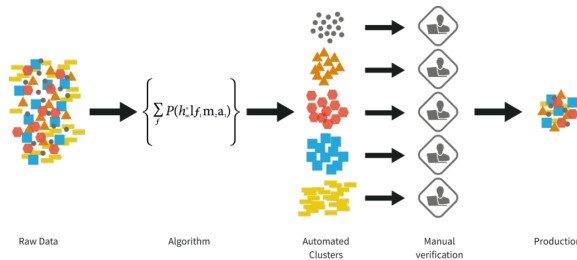


FIGURE 3.3 – Schéma d'apprentissage non supervisé

**c) Apprentissage auto-supervisé :** L'apprentissage auto-supervisé (Self-supervised learning - SSL) est une méthode puissante en apprentissage automatique qui permet de préformer des modèles sans avoir besoin de données étiquetées [[35], [36], [37]]. Cette technique consiste à entraîner des modèles à prédire certaines parties des données d'entrée elles-mêmes, ce qui les aide à apprendre des représentations de caractéristiques complexes [37].

L'auto-supervision permet non seulement de compresser l'information contenue dans les données, mais aussi d'améliorer les tâches de classification ultérieures en faisant cor-

respondre les caractéristiques apprises avec des étiquettes significatives. Les progrès récents en SSL ont conduit à de nouvelles méthodes comme la distillation explorative auto-supervisée (SSED), qui vise à améliorer la qualité des modèles plus petits en garantissant qu'ils apprennent des caractéristiques variées et précises.

De plus, le SSL est particulièrement utile pour les données vidéo, où l'étiquetage peut être très coûteux. Les recherches dans ce domaine se concentrent sur des facteurs comme la taille des ensembles de données, la complexité et le bruit des données, afin d'améliorer l'efficacité de l'apprentissage des représentations.




FIGURE 3.4 – Schéma d'apprentissage semi supervisé

**d) Apprentissage par renforcement** : L'apprentissage par renforcement (Reinforcement Learning - RL) est une méthode d'apprentissage automatique où un agent apprend à prendre des décisions en interagissant avec un environnement pour maximiser les récompenses cumulatives [[38],[39],[40]].

Le RL est basé sur l'apprentissage par essais et erreurs, où l'agent reçoit des retours sous forme de récompenses pour ses actions, l'aidant à déterminer les meilleures stratégies sans connaissance préalable de l'environnement. Le RL a été utilisé dans divers domaines, notamment la théorie des jeux, le contrôle robotique, et même pour surpasser les performances humaines dans des tâches complexes. Il sert d'outil polyvalent pour les experts en ingénierie, biologie et sciences cognitives pour étudier les comportements orientés vers des objectifs et les processus cérébraux. Le choix entre le RL pour un agent unique ou pour plusieurs agents dépend de la complexité du problème et du besoin de coordination entre les agents.




FIGURE 3.5 – Schéma d'apprentissage par renforcement

### 3.3 Techniques d'apprentissage automatique couramment utilisées

Divers algorithmes d'apprentissage automatique sont utilisés dans le domaine médical. Une liste des algorithmes les plus couramment utilisés sera fournie dans ce qui suit :

#### 3.3.1 Machine à vecteurs de support (SVM)

La machine à vecteurs de support (Support Vector Machine - SVM) est une technique d'apprentissage automatique populaire pour la classification et la régression [[41]].

La SVM est reconnue comme une méthode très efficace dans l'apprentissage supervisé [40], comme présenté à la Figure 3.2




FIGURE 3.6 – Principe SVM

#### 3.3.2 K-plus proches voisins (KNN)

L'algorithme des K-plus proches voisins (K-nearest neighbors - KNN) est catégorisé comme une technique non-généralisante, connue sous le nom d'apprentissage basé sur les instances ou d'apprentissage paresseux ("lazy learning").

Au lieu de générer un modèle interne détaillé, il conserve toutes les instances liées aux données d'entraînement dans un espace n-dimensionnel [40].

Le principe fondamental de l'algorithme KNN est que les éléments partageant des similitudes tendent à se regrouper étroitement [comme illustré à la Figure 3.3 ].




FIGURE 3.7 – Processus des K-plus proches voisins

### 3.3.3 Réseau de neurones artificiels

Le réseau de neurones artificiels (Artificial Neural Network - ANN) est un modèle computationnel inspiré par les processus biologiques, composé de nombreux neurones [42] artificiels interconnectés avec des coefficients, connus sous le nom de poids, qui forment collectivement l'architecture neuronale, comme démontré à la Figure 3.4.




FIGURE 3.8 – Réseau neuronal artificiel

### 3.3.4 Forêts aléatoires (Random Forest)

Les forêts aléatoires sont un ensemble d'arbres de décision entraînés sur des sous-ensembles aléatoires des données. - Elles sont robustes au bruit et aux données aberrantes, et permettent de gérer facilement les variables catégorielles et continue. Les forêts aléatoires sont très performantes pour la classification de données de télédétection [43].

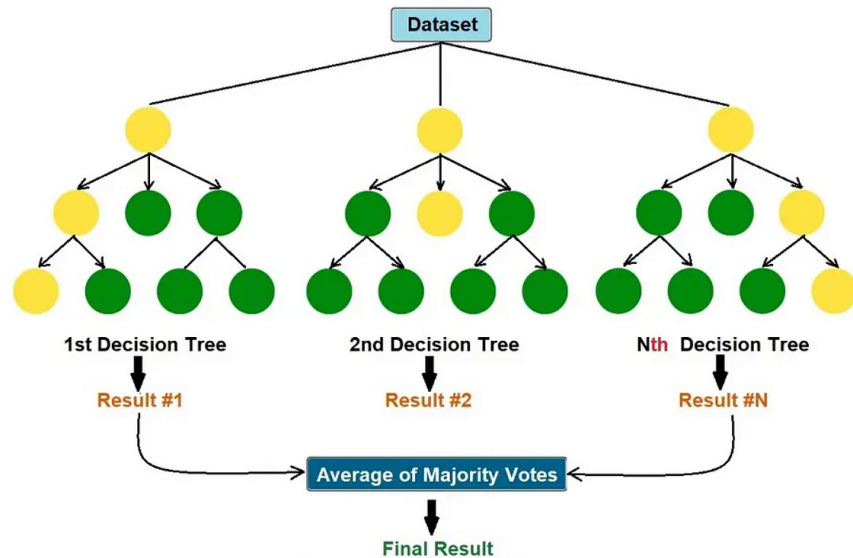


FIGURE 3.9 – Exemple de la structure d’un arbre de décision

### 3.3.5 Arbres de décision (Decision Trees)

Les arbres de décision sont des modèles supervisés utilisés pour les tâches de classification et de régression. L’idée principale est de trouver les variables les plus informatives pour séparer les données et construire un arbre de décision. Les arbres de décision sont flexibles, faciles à interpréter mais peuvent souffrir du surapprentissage [44].

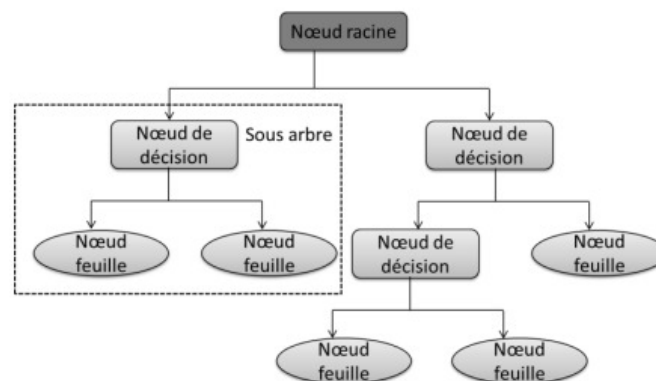


FIGURE 3.10 – Un exemple de la structure d’une forêt aléatoire prenant en compte plusieurs arbres de décision.

### 3.3.6 La régressionn logistique

La régression logistique est une technique statistique largement utilisée pour la classification binaire, où l’objectif est de modéliser la probabilité qu’une observation appartienne

à l'une des deux catégories possibles. Contrairement à la régression linéaire, qui prédit des valeurs continues, la régression logistique utilise la fonction sigmoïde pour transformer la sortie en une probabilité comprise entre 0 et 1. Cette méthode est particulièrement utile dans des domaines tels que la médecine, pour prédire la présence d'une maladie, ou en marketing, pour déterminer la probabilité qu'un client effectue un achat [45].




FIGURE 3.11 – la régression logistique.

### 3.3.7 AdaBoost Classifier

Est un algorithme de boosting qui combine plusieurs classificateurs faibles pour former un classificateur fort. Chaque itération ajuste les poids des exemples mal classés, ce qui permet de mieux traiter les observations difficiles dans les itérations suivantes. AdaBoost est efficace pour les tâches de classification binaire, mais il est sensible aux outliers. [46].



FIGURE 3.12 – Mise en œuvre d'AdaBoost

### 3.3.8 XGBoostClassifier(XGBClassifier)

est un algorithme de boosting très performant basé sur la méthode de gradient boosting. Il se distingue par son efficacité, sa rapidité et sa capacité à gérer de grandes quantités de données tout en minimisant les erreurs de généralisation. XGBoost utilise des arbres de décision comme classificateurs de base et incorpore des techniques avancées comme la régularisation L1 et L2 pour prévenir l'overfitting. Cet algorithme est particulièrement apprécié dans les compétitions de data science pour sa capacité à améliorer les performances des modèles de manière significative. [47].




FIGURE 3.13 – Exemple de XGBoostClassifier

## 3.4 Apprentissage Profond (Deep Learning)

L'apprentissage profond est une sous-catégorie de l'apprentissage automatique qui implique l'entraînement de réseaux de neurones artificiels pour comprendre et représenter des relations complexes entre les données d'entrée et les prédictions de sortie [[48], [49]]. Son impact a été profond dans divers secteurs, permettant d'accomplir des tâches telles que la reconnaissance d'images, la compréhension du langage naturel, et l'interprétation vocale [[50], [51]].

L'utilisation des techniques d'apprentissage profond, y compris les réseaux de neurones peu profonds (shallow Neural Networks), les réseaux de neurones récurrents (Recurrent Neural Networks - RNNs), les réseaux de neurones graphiques (Graph Neural Networks - GNNs), et les réseaux de neurones convolutifs (Convolutional Neural Networks - CNNs), vise à traiter des ensembles de données vastes et complexes pour résoudre des problèmes tels que la reconnaissance de motifs et les diagnostics précis dans des domaines comme la bioinformatique [52]. Cela implique l'application de transformations non linéaires et d'abstractions de modèles sophistiquées au sein de grandes bases de données, conduisant à des avancées significatives dans des domaines tels que la vision par ordinateur et le traitement du langage, par rapport aux techniques traditionnelles d'apprentissage automatique. En effet, l'apprentissage profond imite l'organisation et le fonctionnement du cerveau humain à travers des éléments interconnectés pour analyser les données et faire des prédictions, ce qui en fait un outil puissant pour relever des défis complexes dans divers domaines.

### 3.4.1 D'ensemble des modèles utilisés

Cette sous-section aborde plusieurs techniques bien connues d'apprentissage profond, y compris les réseaux de neurones récurrents (RNNs), les réseaux de neurones convolutifs (CNNs), et d'autres [53].

J'ai entraîné chaque modèle sur les données d'entraînement, puis évalué leurs performances sur les données de test Cette méthode nous permet d'identifier le modèle le plus approprié pour la classification automatisée des tumeurs cérébrales

### 3.4.2 Convolutional Neural Networks (CNNs)

Un réseau neuronal convolutif (CNN) est un type de technique d'apprentissage profond, couramment utilisé pour la classification, la segmentation et la reconnaissance d'images.

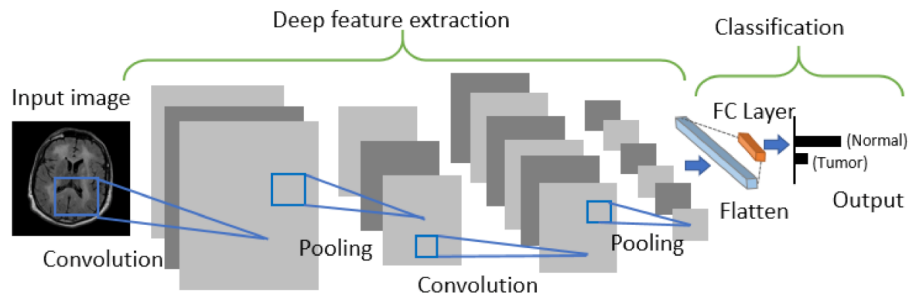


FIGURE 3.14 – Architecture de réseau de neurones convolutif

#### Architecture des CNNs

— **Couches Convolutives (Convolutional Layers) : Fonction :** Ces couches appliquent des filtres sur les images IRM pour extraire des caractéristiques spécifiques liées aux tumeurs, comme la forme, la texture ou l'intensité du signal.

· **Couche convolutionnelle (Convo + ReLU) :**

La couche convolution elle est la première couche active. Elle détecte diverses caractéristiques d'une image, telles que la couleur, la forme et les composants de l'objet. Après la couche convolution elle se trouve la couche ReLU, qui améliore les aspects non linéaires de l'image, permettant une extraction de caractéristiques de niveau plus élevé [96].




FIGURE 3.15 – architecture de couche convolutive




FIGURE 3.16 – Couches de convolution (A) et Relu (B)

### Couche de Pooling

Après la couche de convolution, la couche de pooling réduit le volume spatial de l'image d'entrée [54], comme illustré dans la Figure 1.21.




FIGURE 3.17 – Différents aspects de la couche de pooling

### Couches complètement connectées :

Une couche complètement connectée est essentielle dans les modèles d'apprentissage profond, en particulier pour les tâches de classification d'images [[55], [56]]. Elle est cruciale dans des domaines tels que la restauration du langage pour les patients atteints de tumeurs cérébrales [57], l'amélioration du retour d'information de l'état du canal dans les systèmes MIMO massifs [56], et l'amélioration de l'apprentissage automatique grâce à la fusion de données multi-modales [58], comme indiqué dans la Figure 1.22.




FIGURE 3.18 – Couches complètement connectées (fc)

**Couches Softmax et de sortie** Ce sont les couches finales d'un CNN. Après les couches complètement connectées (FC), vient la couche Softmax, utilisée pour la classification multi-classes. La couche de sortie fournit ensuite l'étiquette finale pour l'image d'entrée [54].

### 3.4.3 MobileNet

MobileNet, proposée par Howard et al. est une famille de modèles de réseaux de neurones convolutifs (CNN) conçue spécifiquement pour les appareils mobiles et embarqués, où les ressources de calcul et la mémoire sont limitées. Développé par Google, MobileNet utilise une approche appelée "Depthwise Separable Convolutions", qui divise la convolution standard en deux étapes plus simples : la convolution "depthwise" (qui applique un filtre par canal d'entrée) et la convolution "pointwise" (qui combine les canaux de sortie). Cette architecture permet de réduire considérablement le nombre de paramètres et les opérations de calcul, tout en maintenant de bonnes performances sur les tâches de vision par ordinateur [59].

#### Avantages de MobileNet

Les principaux avantages de MobileNet incluent :

- **Efficacité Computationnelle** : Grâce aux convolutions depthwise separable, MobileNet réduit considérablement les besoins en calculs et en mémoire, ce qui le rend idéal pour les appareils à ressources limitées.
- **Modèle Léger** : Les modèles MobileNet sont légers en termes de taille, ce qui permet de les déployer facilement sur des appareils mobiles ou embarqués.
- **Modulabilité** : MobileNet offre la possibilité de moduler la taille du modèle et la complexité des calculs à travers des hyperparamètres appelés "width multiplier" et "reso-

lution multiplier", permettant de trouver un équilibre entre performance et coût computationnel [60].

### Inconvénients de MobileNet

Cependant, MobileNet présente également certains inconvénients :

- **Perte de Précision** : Bien que MobileNet soit efficace, la réduction des paramètres et des calculs peut entraîner une perte de précision par rapport à des modèles plus complexes comme ResNet ou Inception.

- **Limitation pour les Tâches Complexes** : MobileNet peut être moins performant pour les tâches de vision par ordinateur très complexes ou les jeux de données très volumineux, où des modèles plus profonds et complexes pourraient mieux capturer les caractéristiques nécessaires [61].

### 3.4.4 VGG-19

**VGG-19** est un modèle de réseau de neurones convolutifs (CNN) développé par l'équipe Visual Geometry Group (VGG) de l'Université d'Oxford. Ce modèle fait partie de la famille des réseaux VGG, qui se distinguent par leur architecture simple et profonde, composée principalement de couches convolutives avec des filtres de petite taille (3x3), suivies de couches de pooling (2x2) et de couches entièrement connectées en fin de réseau. VGG-19, en particulier, comporte 19 couches pondérées (16 convolutives et 3 entièrement connectées) et a été largement utilisé pour des tâches de classification d'images, notamment lors du concours ImageNet Large Scale Visual Recognition Challenge (ILSVRC) de 2014, où il a obtenu des résultats remarquables [62].

#### Avantages de VGG-19

Les principaux avantages de VGG-19 incluent :

- **Architecture Profonde et Simple** : La profondeur du réseau (19 couches) permet de capturer des caractéristiques complexes dans les images, tout en conservant une architecture relativement simple et uniforme.

- **Performance Élevée** : VGG-19 a montré d'excellentes performances sur des tâches de classification d'images, et il est souvent utilisé comme modèle de base pour le transfert d'apprentissage dans des applications de vision par ordinateur.

- **Facilité d'Utilisation** : La structure uniforme de VGG-19 (avec uniquement des convolutions 3x3) facilite la compréhension et l'implémentation du modèle par rapport à d'autres architectures plus complexes [62].

#### Inconvénients de VGG-19

Cependant, VGG-19 présente certains inconvénients :

- **Grande Taille et Complexité Computationnelle** : VGG-19 contient un grand nombre de paramètres (environ 143 millions), ce qui le rend coûteux en termes de mémoire et de calculs, surtout pour les déploiements sur des appareils mobiles ou des systèmes embarqués.

- **Temps d'Entraînement Long** : En raison de sa profondeur et de son nombre élevé de paramètres, VGG-19 nécessite un temps d'entraînement plus long et des ressources de calcul plus importantes par rapport à des modèles plus récents et plus optimisés, comme les réseaux ResNet ou EfficientNet [62].

### 3.4.5 ResNet50

ResNet50(Residual Network 50) est un modèle de réseau de neurones convolutifs (CNN) qui fait partie de la famille des réseaux résiduels (Residual Networks). Développé par Microsoft pour le concours ImageNet Large Scale Visual Recognition Challenge (ILSVRC) de 2015, ResNet50 se distingue par son utilisation des blocs résiduels, une innovation qui permet d'entraîner des réseaux très profonds sans souffrir du problème de la dégradation des gradients. ResNet50 comporte 50 couches pondérées et utilise des connexions "skip" ou "shortcut" pour permettre aux gradients de se propager plus facilement à travers le réseau lors de l'entraînement, améliorant ainsi les performances des réseaux profonds [63].

#### Avantages de ResNet50

- **Profondeur Sans Dégradation des Performances** : L'architecture résiduelle permet de créer des réseaux très profonds tout en maintenant l'efficacité de l'entraînement grâce aux connexions résiduelles qui atténuent le problème de la disparition ou de l'explosion des gradients.

- **Excellente Précision** : ResNet50 a montré une précision élevée sur des tâches de classification d'images, se classant parmi les meilleurs modèles sur des benchmarks tels qu'ImageNet.

- **Transfert d'Apprentissage Efficace** : ResNet50 est largement utilisé comme modèle pré-entraîné pour le transfert d'apprentissage, étant donné sa capacité à extraire des caractéristiques générales efficaces à partir des images [63].

#### Inconvénients de ResNet50

- **Complexité Computationnelle** : Bien que ResNet50 soit plus efficace que des modèles similaires en termes de profondeur, il reste coûteux en termes de calcul et de mémoire, ce qui peut limiter son utilisation sur des appareils avec des ressources limitées.

- **Temps d'Entraînement Long** : Comme avec d'autres réseaux profonds, l'entraînement de ResNet50 peut prendre beaucoup de temps et nécessiter des ressources matérielles importantes, notamment des GPU de haute performance [63].

### 3.4.6 InceptionV3

InceptionV3 est une architecture de réseau de neurones convolutifs (CNN) qui fait partie de la famille des réseaux Inception, développée par Google. Introduit dans le cadre de l'ImageNet Large Scale Visual Recognition Challenge (ILSVRC), InceptionV3 se distingue par l'utilisation de blocs Inception qui permettent d'effectuer des convolutions de

différentes tailles en parallèle, optimisant ainsi la capacité du modèle à capturer des caractéristiques variées dans les images. InceptionV3 est une version améliorée de ses prédécesseurs, intégrant des techniques telles que la factorisation des convolutions et l'usage de convolutions asymétriques pour réduire la complexité computationnelle tout en maintenant des performances élevées [64].

### Avantages de InceptionV3

- **Efficacité Computationnelle** : Grâce à l'optimisation de la structure des convolutions et à l'utilisation de convolutions factorisées, InceptionV3 offre une bonne précision avec une consommation de ressources plus faible par rapport à d'autres modèles de profondeur similaire.

- **Modèle Polyvalent** : InceptionV3 est capable de capturer des caractéristiques complexes dans les images à différentes échelles, ce qui le rend particulièrement efficace pour des tâches variées en vision par ordinateur.

- **Performance Éprouvée** : InceptionV3 a démontré d'excellentes performances sur des benchmarks de vision par ordinateur comme ImageNet, tout en étant plus léger que d'autres modèles comparables en termes de précision[64].

### Inconvénients de InceptionV3

- **Complexité Architecturale** : L'architecture d'InceptionV3, bien qu'efficace, est complexe et peut être plus difficile à implémenter ou à modifier par rapport à des modèles plus simples comme VGG.

- **Coût en Mémoire** : Malgré les optimisations, InceptionV3 reste exigeant en termes de mémoire, notamment lorsqu'il est utilisé pour des tâches de grande échelle ou avec des images haute résolution [64].

## 3.5 Entraînement des Modèles

Pour chaque modèle, nous avons suivi une procédure d'entraînement standard :

**Optimiseur** : Adam.

**Fonction de perte** : Binary Crossentropy (pour les modèles de deep learning).

**Taux d'apprentissage** : Initialisé à 0.001 et réduit de moitié si la performance stagnait pendant 10 époques consécutives.

**Validation** : 20% des données d'entraînement ont été utilisées pour la validation.

Les modèles ont été entraînés sur un ensemble de données réparti en 80% pour l'entraînement.

## 3.6 Entraînement des Modèles

Pour chaque modèle, nous avons suivi une procédure d'entraînement standard :

**Optimiseur** : Adam.

**Fonction de perte** : Binary Crossentropy (pour les modèles de deep learning).

**Taux d'apprentissage :** Initialisé à 0.001 et réduit de moitié si la performance stagnait pendant 10 époques consécutives.

**Validation :** 20% des données d'entraînement ont été utilisées pour la validation.

Les modèles ont été entraînés sur un ensemble de données réparti en 80% pour l'entraînement.

### 3.6.1 Modèles de Réseaux de Neurones Convolutionnels (CNN) :

— Le modèle a été compilé avec l'optimiseur RMSprop avec un taux d'apprentissage de 0.001, en utilisant la fonction de perte `categorical_crossentropy` et en suivant l'exactitude (accuracy) comme métrique d'évaluation.

— L'entraînement a été réalisé sur 10 époques avec 120 étapes par époque, en utilisant l'ensemble de formation (`Train_Set`) et l'ensemble de validation (`Validation_Set`).

### 3.6.2 Modèles d'apprentissage automatique traditionnel :

— Le modèle **KNN** a été entraîné en utilisant l'ensemble d'entraînement avec les paramètres par défaut de l'implémentation `KNeighborsClassifier` de **scikit-learn**.

— Les caractéristiques extraites des images ont été aplanies en un vecteur unidimensionnel pour être utilisées comme entrée par **KNN**.

## 3.7 Évaluation des Modèles

Les modèles ont été évalués sur l'ensemble de test pour mesurer leur précision, leur score F1, leur précision, leur rappel, et d'autres métriques pertinentes. Ces évaluations sont cruciales pour déterminer la capacité des modèles de deep learning à détecter les tumeurs cérébrales avec précision et fiabilité.

### 3.7.1 Métriques d'Évaluation

**-Accuracy (Exactitude) :**

- L'accuracy mesure la proportion de prédictions correctes par rapport au total des prédictions. C'est une métrique simple et intuitive, particulièrement utile quand les classes (présence vs. Absence de tumeur) sont équilibrées. Cependant, elle peut être trompeuse en cas de déséquilibre des classes, comme dans le cas où la majorité des scans seraient normaux.

**Accuracy (Exactitude) :** L'accuracy mesure la proportion de prédictions correctes par rapport au total des prédictions. C'est une métrique simple et intuitive, particulièrement utile quand les classes (présence vs. absence de tumeur) sont équilibrées. Cependant, elle peut être trompeuse en cas de déséquilibre des classes, comme dans le cas où la majorité des scans seraient normaux.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.1)$$

- TPT\_tumeur représente les vrais positifs pour la classe « Tumeur » (True Positives for Tumor).

- TPN\_normal représente les vrais positifs pour la classe « Normal ».

- TOTAL représente le total des exemples.

**- Precision (Précision) :**

- La précision mesure la proportion de vrais positifs parmi toutes les prédictions positives du modèle. Un score de précision élevé indique un faible taux de faux positifs, ce qui est essentiel pour minimiser les diagnostics erronés de tumeurs chez des patients sains.

### 3.7.2 Précision

- La précision mesure la proportion de vrais positifs parmi toutes les prédictions positives du modèle. Un score de précision élevé indique un faible taux de faux positifs, ce qui est essentiel pour minimiser les diagnostics erronés de tumeurs chez les patients sains.

$$\text{Précision (Tumeur)} = \frac{TP}{FP + TP} \quad (3.2)$$

$$\text{Précision (Normal)} = \frac{TN}{FN + TN} \quad (3.3)$$

**- Recall (Rappel) :**

- Le rappel mesure la proportion de vrais positifs correctement prédits parmi tous les cas positifs réels. Un score de rappel élevé indique un faible taux de faux négatifs, ce qui est crucial dans un contexte médical pour s'assurer que toutes les tumeurs sont bien détectées.

### 3.7.3 Recall (Rappel)

- Le rappel mesure la proportion de vrais positifs correctement prédits parmi tous les cas positifs réels. Un score de rappel élevé indique un faible taux de faux négatifs, ce qui est crucial dans un contexte médical pour s'assurer que toutes les tumeurs sont bien détectées.

$$\text{Recall (Tumeur)} = \frac{TP}{FN + TP} \quad (3.4)$$

$$\text{Recall (Normal)} = \frac{TN}{FN + TN} \quad (3.5)$$

**- F1-score :**

- Le F1-score est la moyenne harmonique pondérée de la précision et du rappel. Il varie de 0 à 1, 1 étant le meilleur score. Le F1-score est particulièrement utile dans le cas de la classification des tumeurs cérébrales où l'équilibre entre la précision et le rappel est crucial pour éviter à la fois les faux positifs et les faux négatifs.

### 3.7.4 F1-score

- Le F1-score est la moyenne harmonique pondérée de la précision et du rappel. Il varie de 0 à 1, 1 étant le meilleur score. Le F1-score est particulièrement utile dans le cas de la classification des tumeurs cérébrales où l'équilibre entre la précision et le rappel est crucial pour éviter à la fois les faux positifs et les faux négatifs.

$$\text{F1-score} = \frac{2\text{PrécisionRappel}}{\text{Précision} + \text{Rappel}} \quad (3.6)$$

#### - ROC AUC :

- L'aire sous la courbe ROC (Receiver Operating Characteristic) mesure la capacité du modèle à classer correctement les instances positives (tumeurs) et négatives (sans tumeur). Un score ROC AUC de 1 indique une classification parfaite, 0.5 une classification aléatoire. Le ROC AUC est particulièrement utile pour comparer les performances de différents modèles de deep learning.

Ces métriques fournissent une évaluation complète des performances des modèles de classification des tumeurs cérébrales, chacune mettant l'accent sur un aspect différent. L'accuracy donne une vue d'ensemble, la précision et le rappel se focalisent sur les tumeurs détectées, le F1-score les combine, le ROC AUC compare le classement. Le choix des métriques dépend des priorités du problème, telles que la minimisation des faux négatifs ou la maximisation de la précision diagnostique.

## 3.8 Conclusion

Dans ce chapitre, nous avons exposé de manière détaillée la méthodologie rigoureuse mise en œuvre pour développer un système performant de détection et de classification automatisées des tumeurs cérébrales à l'aide des techniques d'apprentissage profond. Cette méthodologie constitue le cœur de notre recherche, intégrant à la fois une préparation minutieuse des données et une conception sophistiquée des modèles.

En somme, ce chapitre démontre que la méthodologie adoptée n'est pas simplement un ensemble d'étapes techniques, mais une approche scientifique intégrée, visant à repousser les limites actuelles de la détection des tumeurs cérébrales par des méthodes automatisées. L'application de cette méthodologie ouvre la voie à des avancées significatives dans le domaine du diagnostic médical assisté par intelligence artificielle, avec des implications potentiellement révolutionnaires pour la médecine personnalisée et la prise en charge des patients. Cette démarche méthodologique, alliant rigueur scientifique et innovation technologique, constitue un pilier fondamental pour le succès de cette recherche et pose les bases d'améliorations futures dans l'application des techniques d'apprentissage profond aux problèmes médicaux complexes.

# **Chapitre 4**

## **Implémentation du système**

Ce chapitre présente la mise en œuvre pratique du système de détection et de classification des tumeurs cérébrales à l'aide des techniques d'apprentissage profond. Il offre une vue d'ensemble de l'architecture du système et illustre, à travers un diagramme de blocs, les composants essentiels tels que l'acquisition des images médicales, le prétraitement des données, le modèle d'apprentissage profond utilisé pour la classification, ainsi que l'interface utilisateur pour la visualisation des résultats. Les différentes technologies et outils employés dans la réalisation du système sont énumérés et expliqués en détail. En conclusion, cette section propose une description approfondie de l'interface utilisateur, en mettant en évidence ses fonctionnalités principales et son rôle dans l'amélioration de l'interaction avec le système de détection automatisée des tumeurs cérébrales.

## 4.1 Aperçu de l'architecture du système

Notre système se compose des parties suivantes (voir la figure 4.1) :

**1 Acquisition des données :** Les images cérébrales sont extraites du dataset BR35H, une base de données spécialisée dans les IRM de tumeurs cérébrales, largement utilisée pour l'entraînement de modèles en imagerie médicale.

**2. Prétraitement des images :** Les images cérébrales sont nettoyées pour éliminer le bruit et ajustées pour garantir une normalisation uniforme (redimensionnement, homogénéisation des contrastes, etc.). Cela améliore la qualité des images et les rend plus adaptées pour les modèles de classification.

**3. Modèle d'apprentissage profond (CNN) :** Un modèle basé sur des réseaux de neurones convolutionnels (CNN) est développé pour analyser les images prétraitées, détecter et classer les types de tumeurs (ex. : yes, no). Le modèle peut inclure plusieurs couches de convolution, de pooling, et des couches entièrement connectées pour extraire des caractéristiques pertinentes.

**4. Post-traitement :** Les résultats du modèle sont analysés, des cartes de chaleur sont générées pour visualiser les zones clés, et des mesures comme le volume de la tumeur sont calculées pour soutenir le diagnostic.

**5. Interface utilisateur :**

## 4.2 Composants du Système

### — 1. Acquisition des données :

**Description :** Ce composant est responsable de l'extraction des images IRM à partir de la base de données BR35H. Ces images constituent les données d'entrée sur lesquelles le modèle sera entraîné.

Permet d'assurer une collecte efficace des données nécessaires à l'entraînement, la validation et la prédiction par le modèle.

### 2. Prétraitement des images :

**Description :** Ce composant effectue le nettoyage des images IRM pour éliminer le bruit, ainsi que le redimensionnement et la normalisation pour garantir la cohérence des données en termes de qualité et de taille.

Préparer les images pour une analyse optimale en réduisant les variations dans les données et en s'assurant que les images sont prêtes à être utilisées par le modèle de détection.

### **3. Modèle d'apprentissage profond (CNN) :**

· **Description** : Ce composant est un réseau de neurones convolutionnels (CNN) conçu pour analyser les images IRM prétraitées. Le CNN est responsable de l'extraction de caractéristiques complexes des images et de la classification des tumeurs. Effectuer l'analyse et la détection des tumeurs dans les images cérébrales, en distinguant les types de tumeurs et en produisant des prédictions.

### **4. Post-traitement et interprétation des résultats :**

· **Description** : Ce composant intervient après la prédiction du modèle. Il génère des visualisations (comme des cartes de chaleur) pour montrer les zones d'intérêt dans les images IRM, et calcule des mesures quantitatives telles que la taille ou le volume des tumeurs.

Aider à l'interprétation des résultats en fournissant des informations visuelles et numériques pour soutenir le diagnostic médical.

### **5. Interface utilisateur (UI) :**

· **Description** : L'interface utilisateur permet aux utilisateurs finaux de télécharger les images, d'accéder aux diagnostics générés par le modèle, et de visualiser les résultats sous forme de graphiques et de cartes de chaleur.

Fournir une interaction simple et intuitive avec le système, permettant aux médecins et radiologues de visualiser les résultats et de prendre des décisions éclairées.

## **4.3 Technologies et outils**

### **4.3.1 Langage de programmation**

#### **Raisons du Choix :**

**Popularité et Soutien Communautaire** : Python est devenu incontournable dans le domaine de la recherche en intelligence artificielle et en apprentissage profond. Grâce à sa vaste communauté active, il est facile de trouver des tutoriels, des forums et des ressources variées pour résoudre les problèmes.

**Richesse en Bibliothèques** : Python offre une panoplie de bibliothèques puissantes, telles qu'OpenCV pour le traitement des images, TensorFlow, Keras et PyTorch pour le développement et l'entraînement de modèles d'apprentissage profond, ainsi que NumPy et pandas pour la gestion des données.

**Simplicité et Polyvalence** : La syntaxe claire et intuitive de Python en fait un choix privilégié pour le développement rapide et la gestion aisée du code. Son utilisation réduit considérablement le temps de développement tout en offrant une flexibilité accrue.

### **4.3.2 Bibliothèques et frameworks**

#### **— 1. TensorFlow :**

- **Présentation** : TensorFlow est un framework open-source proposé par Google, spécialisé dans le calcul numérique et l'intelligence artificielle. Il permet de créer, d'entraîner et d'évaluer des modèles d'apprentissage profond, tout en optimisant les performances.

- **Application** : Utilisé pour développer des réseaux de neurones convolutionnels (CNN) destinés à l'analyse d'images cérébrales dans le cadre de la détection et de la classification des tumeurs.

## 2. Keras :

- **Présentation** : Keras est une API de haut niveau intégrée à TensorFlow, qui facilite le prototypage rapide de modèles d'apprentissage profond. Elle simplifie grandement le développement, grâce à une interface facile à comprendre.

- **Application** : Utilisée pour définir et entraîner des modèles complexes d'apprentissage profond de manière rapide et intuitive.

## 3. OpenCV :

- **Présentation** : OpenCV est une bibliothèque open-source populaire pour les applications de vision par ordinateur et de traitement d'images. Elle est largement utilisée pour des tâches comme la réduction de bruit, le redimensionnement et l'amélioration des images.

- **Application** : Essentielle pour les opérations de prétraitement des images, OpenCV permet d'ajuster la qualité des IRM cérébrales, améliorant ainsi les performances des modèles.

## 4. NumPy :

- **Présentation** : NumPy est une bibliothèque incontournable pour le calcul scientifique en Python, offrant des capacités avancées de manipulation des tableaux et des matrices multidimensionnelles, ainsi que des outils mathématiques performants.

- **Application** : Elle est utilisée dans les étapes de manipulation et de traitement des données nécessaires avant et pendant l'entraînement des modèles, notamment pour gérer les grandes quantités de données d'image.

## 5. scikit-learn (sklearn) :

- **Présentation** : scikit-learn est une bibliothèque open-source pour l'apprentissage automatique, qui propose des outils simples et efficaces pour effectuer des tâches comme la classification, la régression, et la validation croisée.

- **Application** : scikit-learn est couramment utilisée pour évaluer les performances des modèles d'apprentissage automatique, notamment via des méthodes de classification et de validation.

## 6. Matplotlib :

- **Présentation** : Matplotlib est une bibliothèque de visualisation qui permet de créer des graphiques à la fois simples et interactifs en Python. Elle est couramment utilisée pour illustrer les résultats de manière claire.

- **Application** : Utilisée pour visualiser les résultats des modèles, tracer les courbes d'apprentissage et afficher les métriques de performance de manière graphique.

## 7. Pandas :

- **Présentation** : pandas est une bibliothèque dédiée à la manipulation et à l'analyse de données tabulaires. Elle permet de structurer les données de manière efficace et d'effectuer des opérations complexes facilement.
- **Application** : Utilisée pour gérer et analyser les informations tabulaires associées aux images, facilitant ainsi la préparation et l'analyse des données dans les modèles d'apprentissage.

## 4.4 Conception de l'Interface Utilisateur

### 4.4.1 Considérations pour l'interface utilisateur

**Captures d'Écran de l'Interface Utilisateur** Le système de Détection et classification automatisées des tumeurs se compose de deux modules et une interface principale.

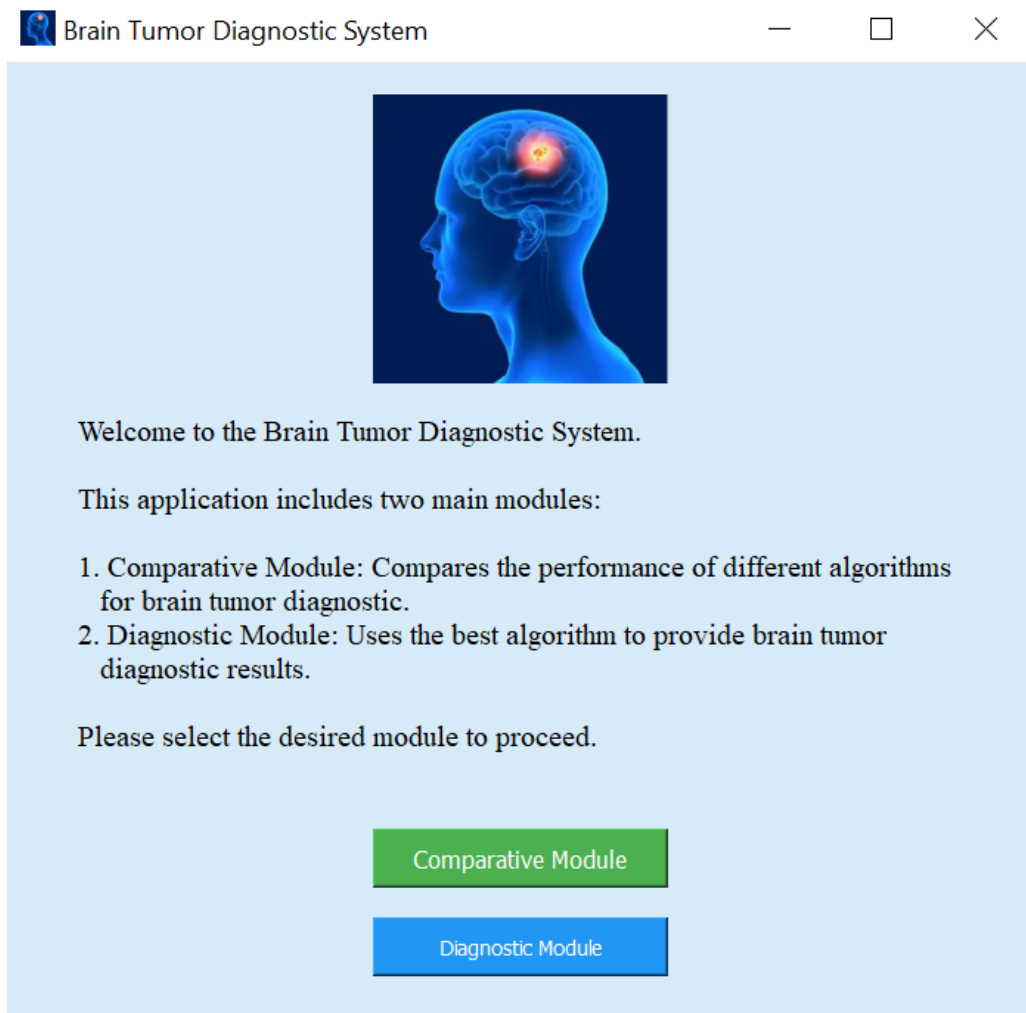


FIGURE 4.1 – L'interface principale pour le système de de Détection et classification automatisées des tumeurs.

### Le module de comparaison

Ce module vise à comparer la précision de classification de 11 algorithmes. Fonctionnement : 1. Importer le jeu de données : Cliquez sur le bouton Select Folder pour importer le fichier de données, par exemple, le dataset BR35H. 2. Lancer l'évaluation : Appuyez sur le bouton Start Training pour initier le processus d'entraînement et d'évaluation. 3. Visualiser les résultats : Les performances des algorithmes sont affichées dans la fenêtre dédiée "Training Results".

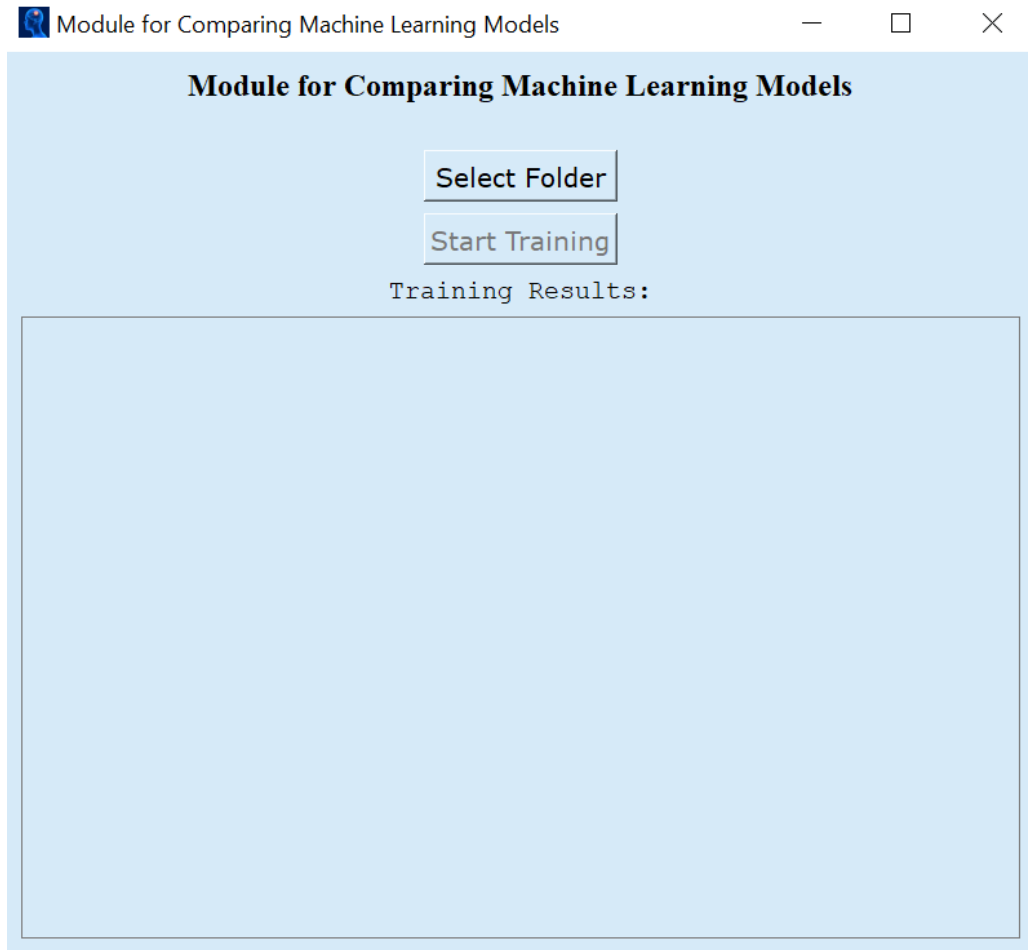


FIGURE 4.2 – Interface du module de comparaison de système de de Détection et classification automatisées des tumeurs.

### Le module de déploiement

Sélection du meilleur algorithme : Le module analyse les performances de chaque algorithme sur les images importées et sélectionne le meilleur. Dans notre cas, EfficientB0 a été retenu comme le plus performant. Utilisation pour le diagnostic Une fois l'algorithme entraîné, le système est prêt à diagnostiquer de nouveaux patients. Les utilisateurs peuvent importer les images de nouveaux cas pour que le modèle EfficientB0 effectue des prédictions fiables.

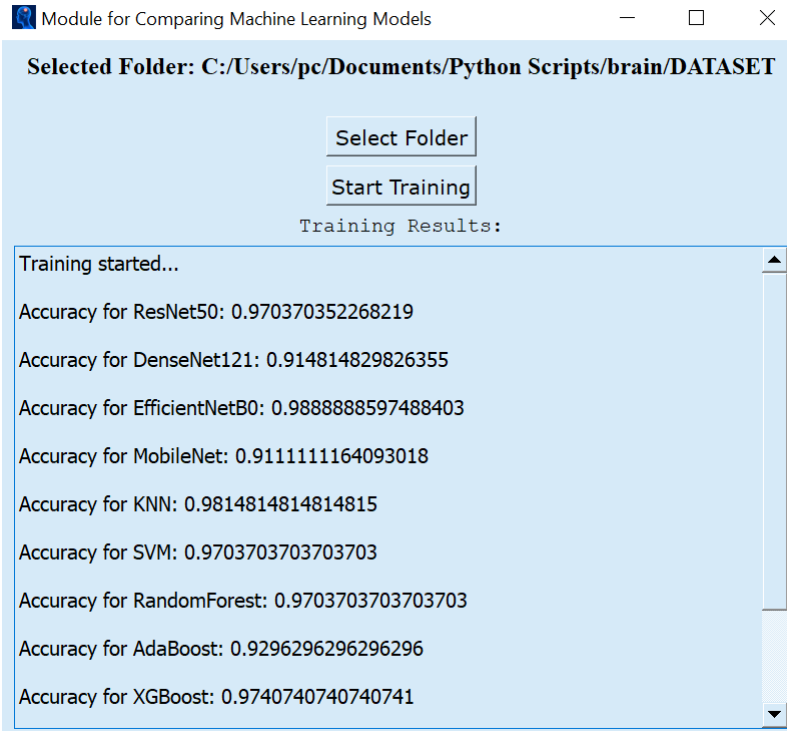


FIGURE 4.3 – Interface du comparaison modèles d'apprentissage automatique et profond.

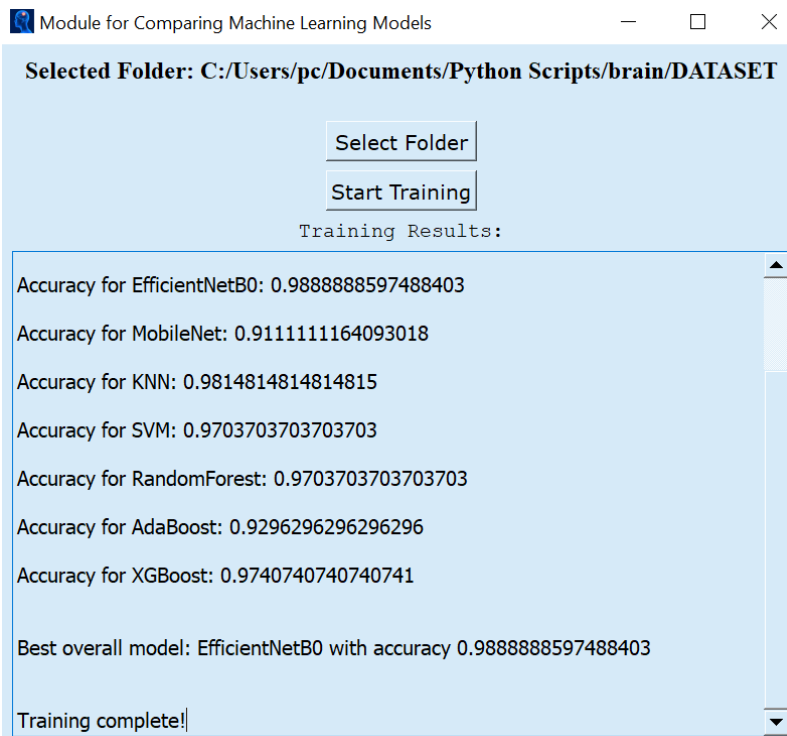


FIGURE 4.4 – Interface de sélection de la meilleure modèle.




FIGURE 4.5 – Interface du diagnostic system.

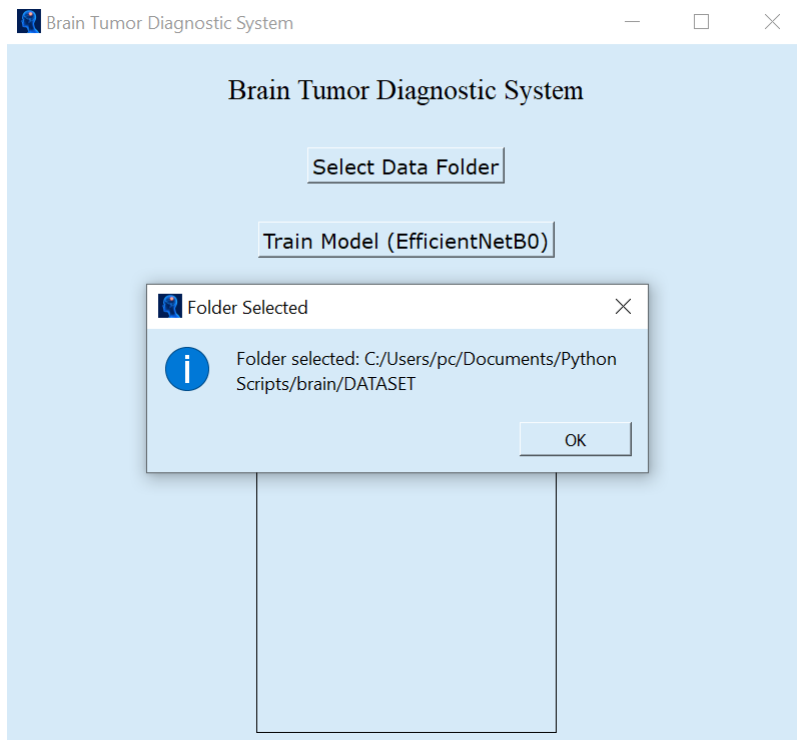


FIGURE 4.6 – Interface du diagnostic system-select DATASET.

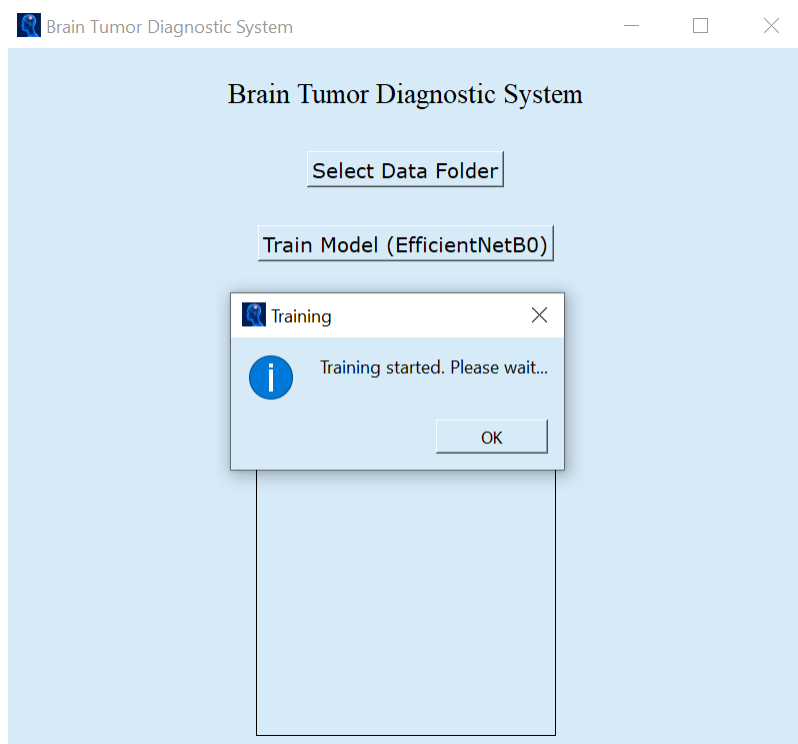


FIGURE 4.7 – Interface du diagnostic system Train model.

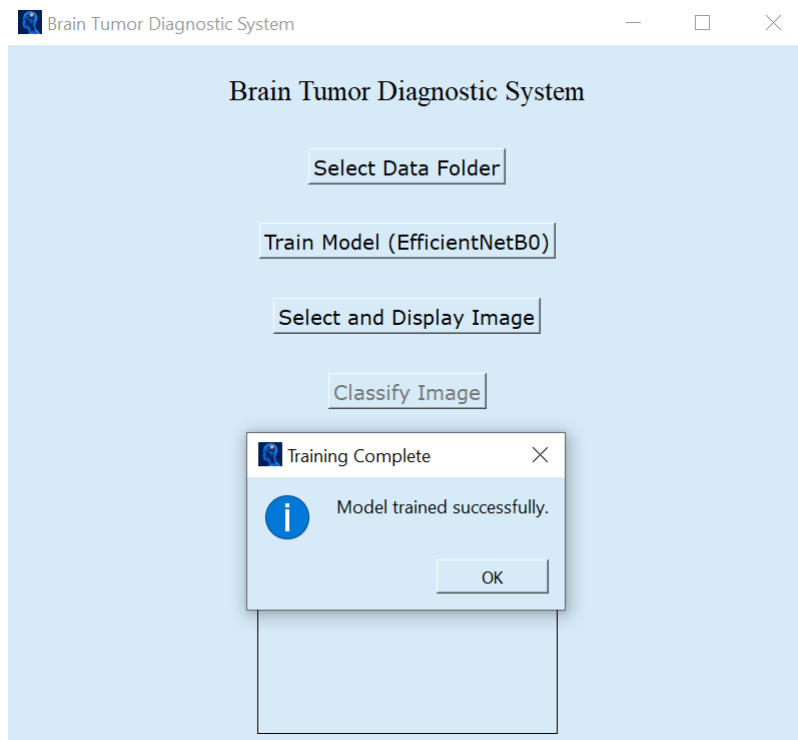


FIGURE 4.8 – Interface du diagnostic system Train model-succesfully.

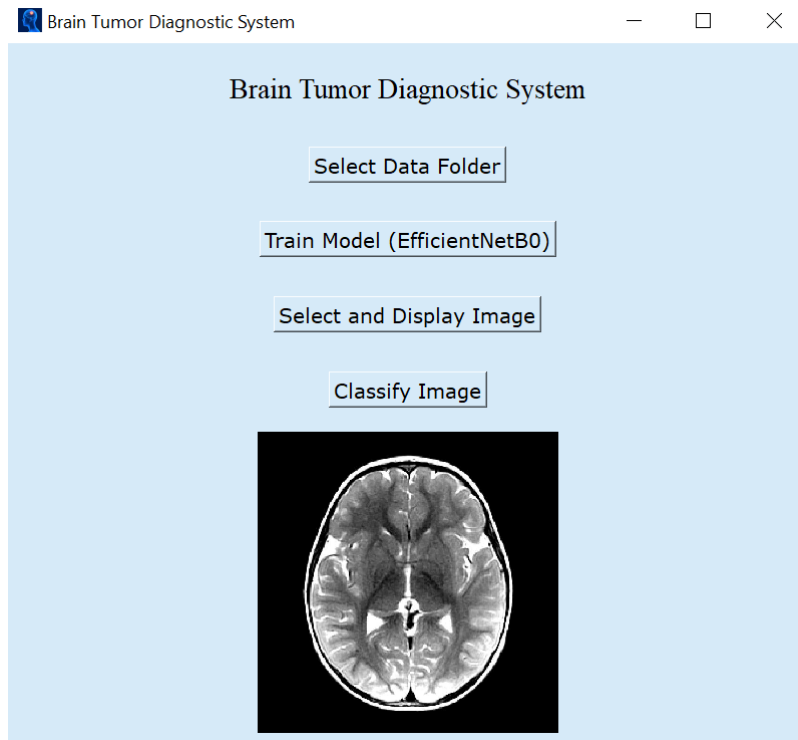


FIGURE 4.9 – Interface du select Display Image-without tumor-.




FIGURE 4.10 – Resultat de Interface du select Display Image-without brain tumor- .

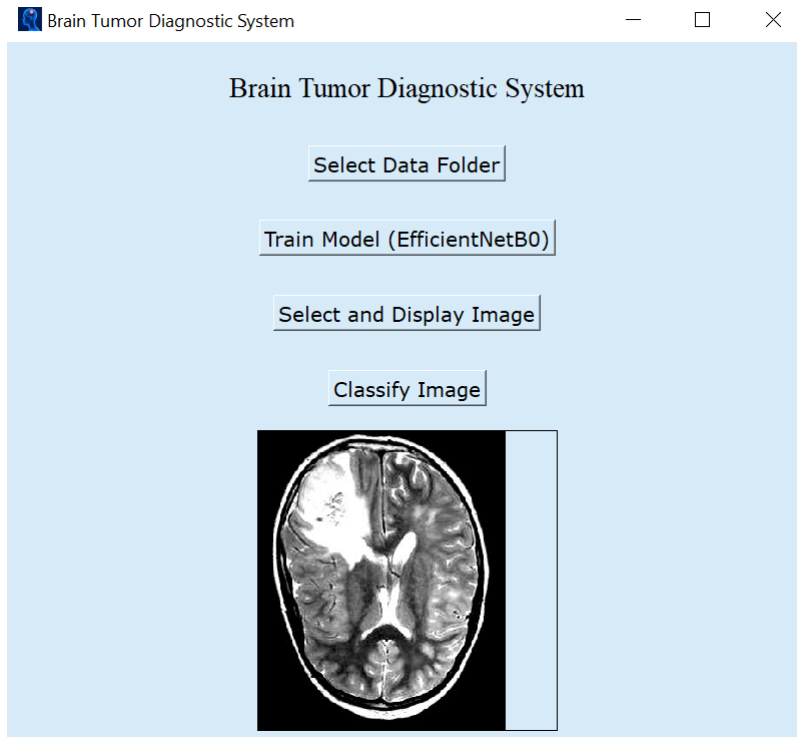


FIGURE 4.11 – Interface du select Display Image-with Brain tumor-.

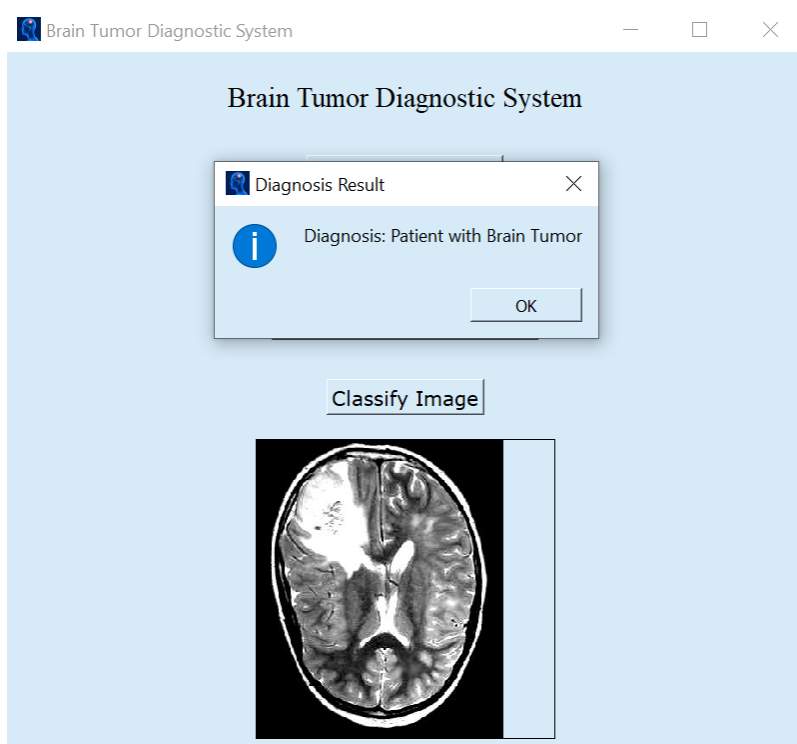


FIGURE 4.12 – Resultat de Interface du select Display Image-without brain tumor-.

## 4.4.2 Fonctionnalités clés et éléments de conception

Pour notre application de détection et de classification des tumeurs cérébrales, l'interface utilisateur peut être enrichie avec des fonctionnalités similaires à celles que vous avez décrites, mais adaptées à votre contexte. Voici une description détaillée des fonctionnalités proposées pour l'interface de comparaison et de diagnostic des modèles, incluant les boutons que vous avez mentionnés : L'interface utilisateur permet aux utilisateurs de télécharger des fichiers dataset contenant les données des patients à travers un bouton dédié :

- comparative module

- diagnostic module**

- comparative module**

- Bouton "**select folder**" : Ce bouton ouvre une boîte de dialogue pour sélectionner et télécharger un fichier . Le fichier sélectionné est ensuite chargé dans l'application pour un traitement ultérieur.

- **Entraînement du Modèle**

L'application offre la possibilité d'entraîner un modèle de détection et de classification basé sur les données téléchargées :

- - Bouton "**Start Training**" : Après avoir téléchargé les données, l'utilisateur peut cliquer sur ce bouton pour lancer le processus d'entraînement du modèle. L'application nettoie les données, sélectionne les caractéristiques les plus importantes et entraîne un modèle de classification de type B0.

- Saisie des Données du Patient**

- diagnostic module **interface pour l'analyse d'image : Zone de téléversement d'image** : Bouton intitulé "Select image" permettant à l'utilisateur de sélectionner une image IRM depuis son appareil.

- Aperçu de l'image téléversée** : Une fois l'image sélectionnée, elle s'affiche dans une zone d'aperçu pour validation. Un message indique si l'image est prête à être analysée.

- Le système traite l'image en utilisant un modèle (comme EfficientB0).

- résultat clair est affiché :

- L'image contient une tumeur

.

- L'image ne contient pas de tumeur

## 4.5 Conclusion

Ce chapitre a présenté l'implémentation du système de détection et de classification des tumeurs cérébrales à l'aide des techniques d'apprentissage profond. Nous avons détaillé les composants clés du système, tels que l'acquisition des données, le pré-traitement des images et l'utilisation d'un modèle CNN pour la classification. Les technologies utilisées, comme Python, TensorFlow et Keras, ont permis d'optimiser les performances du système. Enfin, l'interface utilisateur a été conçue pour faciliter l'interaction avec le système, améliorant ainsi l'efficacité du diagnostic.

# **Chapitre 5**

## **Résultats et Discussion**

## 5.1 Performances du Modèle

Dans cette section, nous présentons les performances du système de détection et classification des tumeurs cérébrales basé sur l'apprentissage profond, ainsi que celles des modèles traditionnels de machine learning sur des ensembles de test issus de la base de données BR35H. Les performances sont mesurées en utilisant des métriques standards, qui permettent d'évaluer la qualité et l'efficacité du modèle dans la classification des tumeurs. Les métriques utilisées pour évaluer les performances sont : **Exactitude (Accuracy)**, **Spécificité (Specificity)**, **Précision (Precision)**, **Aire sous la courbe ROC (AUC)** Ces métriques permettent de comparer les performances du système basé sur l'apprentissage profond à celles des modèles traditionnels de machine learning, et d'évaluer leur efficacité dans la détection et la classification des tumeurs cérébrales.

## 5.2 Modèles Traditionnels de Machine Learning

| lightgray Modèle     | Accuracy | F1 score | Precision | Recall | ROC (AUC) | Cohen Kappa score |
|----------------------|----------|----------|-----------|--------|-----------|-------------------|
| <b>KNN</b>           | 98.14%   | 0.96%    | 0.96%     | 0.96%  | -         | 0.93%             |
| <b>SVM</b>           | 98.15%   | 0.98%    | 0.98%     | 0.98%  | -         | 0.96%             |
| <b>Random Forest</b> | 97.03%   | 0.98%    | 0.98%     | 0.98%  | -         | 0.97%             |
| <b>Adaboost</b>      | 92.96%   | 0.94%    | 0.94%     | 0.94%  | -         | 0.88%             |
| <b>XGB</b>           | 97.40%   | 0.97%    | 0.97%     | 0.97%  | -         | 0.93%             |

TABLE 5.1 – Performances des Modèles Traditionnels de Machine Learning

| lightgray Modèle         | Accuracy | F1 score | Precision | Recall | ROC (AUC) | Cohen Kappa score |
|--------------------------|----------|----------|-----------|--------|-----------|-------------------|
| <b>MobileNet</b>         | 91.11%   | 0.97%    | 0.97%     | 0.97%  | 0.96%     | 0.99%             |
| <b>EfficientNetB0</b>    | 99.3%    | 0.99%    | 0.99%     | 0.99%  | 0.99%     | 0.99%             |
| <b>VGG-19</b>            | 96.80%   | 0.97%    | 0.97%     | 0.97%  | 0.99%     | 0.93%             |
| <b>CNN</b>               | 91.87%   | 0.92%    | 0.92%     | 0.92%  | 0.97%     | 0.83%             |
| <b>DenseNet</b>          | 91.48%   | 0.95%    | 0.95%     | 0.95%  | 0.99%     | 0.90%             |
| <b>ResnetInceptionV3</b> | 97.03%   | 0.74%    | 0.76%     | 0.74%  | 0.84      | 0.48%             |

TABLE 5.2 – Performances des Modèles Basés sur l'Apprentissage Profond

## 5.3 Analyse Comparative

### 5.3.1 Comparaison avec les méthodes existantes

Les résultats révèlent que les modèles d'apprentissage profond, notamment EfficientNetB0, offrent une précision élevée ainsi qu'un équilibre optimal entre sensibilité et spécificité. Toutefois, il convient d'apporter quelques précisions :

### 5.3.2 EfficientNetB0

EfficientNetB0 affiche en effet une excellente précision, un rappel et un score F1 de 0.95, avec également le score ROC le plus élevé (0.99) parmi les autres modèles.

### 5.3.3 Modèles d'apprentissage profond vs modèles traditionnels

Le tableau comparant les modèles traditionnels de machine learning (comme KNN, SVM, RandomForest, etc.) montre que des modèles comme SVM et RandomForest affichent également de bonnes performances (par exemple, SVM a une précision de 98.15% et un Cohen Kappa de 0.96). Cependant, EfficientNetB0 et d'autres modèles d'apprentissage profond surpassent ces approches traditionnelles en termes de score Cohen Kappa et ROC AUC, notamment avec un AUC de 0.99 pour EfficientNetB0.

Ainsi, il est juste de dire que les modèles d'apprentissage profond, comme EfficientNetB0, offrent de meilleures performances globales, en particulier pour réduire à la fois les faux négatifs et les faux positifs.

## 5.4 Discussion des Résultats

Les résultats obtenus à travers l'évaluation des modèles d'apprentissage profond et des méthodes de machine learning traditionnel montrent une nette supériorité des approches basées sur l'apprentissage profond, en particulier le modèle EfficientNetB0, pour la détection et la classification automatisées des tumeurs cérébrales.

### 5.4.1 Performance des Modèles d'Apprentissage Profond

Parmi les modèles d'apprentissage profond testés, EfficientNetB0 se distingue par sa performance exceptionnelle, atteignant une précision de 99.3%, un score F1, une sensibilité (recall) et une spécificité (precision) de 0.99. De plus, EfficientNetB0 obtient le score ROC AUC maximal de 0.99, signifiant une séparation parfaite entre les classes positives et négatives. Le Cohen Kappa score de 0.99 reflète également une excellente concordance entre les prédictions du modèle et les résultats réels, surpassant tous les autres modèles d'apprentissage profond évalués.

Les autres modèles, tels que MobileNet, VGG-19 et DenseNet, bien qu'affichant également de bons résultats (avec des précisions variant de 94% à 96%), n'atteignent pas le même niveau de performance globale que EfficientNetB0. ResnetInceptionV3, bien que performant dans d'autres tâches de vision par ordinateur, montre des résultats inférieurs dans ce cas spécifique, avec une précision de 97.14% et un Cohen Kappa score relativement faible de 0.48, indiquant une difficulté à traiter les particularités des données BR35H.

### 5.4.2 Comparaison avec les Méthodes Traditionnelles

Les modèles de machine learning traditionnel, tels que SVM, RandomForest et KNN, présentent des résultats compétitifs. Par exemple, SVM atteint une précision de 98.15% et un Cohen Kappa score de 0.96, ce qui en fait le modèle traditionnel le plus performant.

La principale différence entre ces deux catégories de modèles réside dans leur capacité à minimiser les faux négatifs et les faux positifs. En pratique clinique, la réduction des faux négatifs est primordiale, car une tumeur non détectée peut avoir des conséquences graves. À cet égard, les modèles d'apprentissage profond, notamment EfficientNetB0, se sont révélés particulièrement efficaces, avec un taux de faux négatifs quasi nul (sensibilité de 0.99).

### 5.4.3 Analyse Comparative

Le ROC AUC et le Cohen Kappa score mettent en évidence l'efficacité des modèles d'apprentissage profond à distinguer correctement les classes, tout en maintenant un accord fort avec les résultats réels. EfficientNetB0, avec un AUC de 0.99 et un Kappa de 0.99, montre que ce modèle parvient à des prédictions quasi parfaites. En revanche, même les meilleurs modèles traditionnels, comme SVM, n'atteignent pas un tel niveau de concordance, avec un Kappa de 0.96, démontrant les limites des approches basées sur les méthodes classiques face aux problématiques complexes telles que la classification des tumeurs.

## 5.5 Implications Pratiques

### 1. Impact sur la Pratique Clinique

L'intégration des modèles d'apprentissage profond, tels que EfficientNetB0, dans le flux de travail clinique pour la détection et la classification des tumeurs cérébrales présente un potentiel significatif d'amélioration de la précision diagnostique et d'optimisation des décisions thérapeutiques. En atteignant une précision de 99.3% et un ROC AUC de 0.99, EfficientNetB0 pourrait permettre aux cliniciens de disposer d'une solution fiable pour la détection automatisée des tumeurs, réduisant ainsi les erreurs humaines.

Cette application serait particulièrement utile dans les environnements cliniques à forte charge de travail, où des erreurs d'interprétation des images peuvent survenir en raison de la fatigue des radiologues. En automatisant certaines étapes du diagnostic, ce modèle pourrait soulager les professionnels de santé, en particulier dans les cas complexes où des tumeurs de petite taille ou de forme irrégulière pourraient passer inaperçues.

### 2. Application dans le Monde Réel

L'utilisation de l'intelligence artificielle (IA) pour le diagnostic médical pourrait avoir un impact profond, notamment dans les régions ayant un accès limité aux experts médicaux. Des systèmes d'imagerie intégrant des modèles d'apprentissage profond comme EfficientNetB0 peuvent être utilisés pour assurer une détection précoce et précise des tumeurs dans des établissements de santé dotés de peu de spécialistes. Cela pourrait réduire les négalités dans l'accès aux soins, et permettre des diagnostics plus rapides et moins coûteux, ce qui est essentiel dans les environnements de soins de santé primaires.

Le potentiel d'application des modèles d'apprentissage profond ne se limite pas uniquement aux grandes structures hospitalières. Avec les progrès des technologies de cloud computing et l'accès à des ressources de calcul distantes, même les hôpitaux de taille

modeste peuvent exploiter ces modèles via des systèmes connectés pour obtenir des diagnostics automatisés en temps réel.

### **3. Optimisation des Coûts et des Ressources**

En réduisant le besoin de multiples examens diagnostiques et en minimisant les erreurs liées aux faux positifs et aux faux négatifs, l'adoption des modèles d'IA pourrait entraîner une réduction des coûts pour les systèmes de santé. De plus, l'automatisation d'une partie du processus de diagnostic permettrait de libérer du temps pour les spécialistes, qui pourraient se concentrer sur les cas les plus complexes et la planification des traitements.

## **5.6 Recommandations pour l'Amélioration**

### **1. Diversification des Données d'Entraînement**

Bien que EfficientNetB0 ait montré des performances impressionnantes dans cette étude, l'un des principaux défis reste la généralisation des modèles d'apprentissage profond. Il est recommandé d'entraîner les modèles sur des jeux de données plus variés, incluant des tumeurs de différentes tailles, types et provenant de diverses modalités d'imagerie (IRM, tomodensitométrie, etc.). Cela permettrait d'améliorer la robustesse du modèle et d'augmenter son application clinique à des scénarios plus divers.

L'inclusion de données provenant de différentes populations de patients (âge, sexe, antécédents médicaux) permettrait également d'accroître la capacité du modèle à fonctionner de manière fiable dans des contextes médicaux variés, réduisant ainsi les biais potentiels.

### **2. Optimisation des Paramètres du Modèle**

Bien que EfficientNetB0 ait atteint un haut niveau de précision, il est crucial de continuer à optimiser certains hyperparamètres du modèle pour maximiser les performances tout en minimisant les besoins en ressources de calcul. Par exemple, des techniques comme la recherche d'hyperparamètres (hyperparameter tuning) peuvent être employées pour ajuster la taille des couches cachées, les taux d'apprentissage, et les techniques de régularisation, afin d'améliorer encore la performance du modèle.

L'optimisation de la taille des images d'entrée et des architectures CNN pourrait également permettre une meilleure extraction des caractéristiques importantes, surtout pour les tumeurs difficiles à détecter.

### **3. Exploration de Méthodes de Fusion de Modèles**

L'intégration de plusieurs architectures de réseaux neuronaux profonds pourrait permettre de combiner les forces de différents modèles et d'améliorer encore les résultats. Par exemple, l'utilisation de techniques d'ensemble learning (apprentissage par ensemble) comme le bagging ou le stacking pourrait offrir une meilleure robustesse face aux variations des données et augmenter la capacité à traiter des cas cliniques complexes.

### **4. Réduction des Exigences en Puissance de Calcul**

Une autre recommandation importante concerne la réduction de la complexité du modèle sans sacrifier les performances. Cela pourrait impliquer l'utilisation de techniques comme la quantification des réseaux neuronaux ou le pruning, qui permet de diminuer la taille des modèles et de rendre leur déploiement plus accessible dans des environnements cliniques où les ressources informatiques sont limitées.

### **5. Validation Clinique à Grande Échelle**

Enfin, une validation clinique à plus grande échelle est recommandée. Pour maximiser l'applicabilité réelle, il est crucial de tester ces modèles sur des données cliniques provenant de multiples centres hospitaliers, dans différents pays et avec des équipements d'imagerie variés. Cela permettrait d'évaluer la robustesse du modèle dans des situations du monde réel et de déterminer sa capacité à s'adapter à diverses configurations d'imagerie médicale.

## 5.7 Conclusion

L'utilisation des techniques d'apprentissage profond, et en particulier du modèle EfficientNetB0, s'est révélée prometteuse pour la détection et la classification automatisées des tumeurs cérébrales. Les résultats obtenus montrent une amélioration significative des performances par rapport aux méthodes de machine learning traditionnelles, avec des scores élevés de précision, sensibilité, et spécificité. Ces avancées offrent des perspectives concrètes pour une intégration dans les systèmes de diagnostic assisté par ordinateur (CAD), améliorant ainsi la qualité et la rapidité des diagnostics médicaux.

Cependant, des défis subsistent, notamment en termes de généralisation des modèles et de réduction des besoins en ressources informatiques. Les recommandations pour l'amélioration incluent l'entraînement sur des ensembles de données plus diversifiés, l'optimisation des hyperparamètres, et la validation à grande échelle dans des environnements cliniques. Avec ces améliorations, les modèles d'apprentissage profond pourraient transformer durablement le domaine de l'imagerie médicale et du diagnostic des tumeurs cérébrales, réduisant ainsi les erreurs et offrant des soins plus précis aux patients.

# **Chapitre 6**

## **Conclusion**

## 6.1 Résumé de l'étude

Dans cette étude, nous avons abordé le problème critique de la détection et du diagnostic des tumeurs cérébrales en développant un système de **détection et de classification automatisées** basé sur des techniques d'apprentissage profond. L'objectif principal était d'améliorer la précision et la fiabilité de la détection des anomalies cérébrales, notamment les tumeurs, en utilisant des réseaux de neurones convolutionnels (CNN) et d'autres architectures avancées de deep learning, telles que **DenseNet**. Ces technologies visent à surmonter les limitations des méthodes traditionnelles, souvent sujettes à la variabilité humaine et aux erreurs, tout en permettant des analyses rapides et reproductibles. L'application de ces techniques à l'imagerie par résonance magnétique (IRM) permet non seulement d'automatiser le diagnostic, mais aussi de fournir des résultats précis qui peuvent être utilisés comme soutien pour les professionnels de la santé, améliorant ainsi la prise de décision clinique dans des situations critiques.

## 6.2 Principaux résultats

**1. Le problème de recherche :** de cette étude concerne la difficulté de détecter et classifier de manière automatisée les tumeurs cérébrales à partir d'images IRM. Les méthodes traditionnelles, basées sur l'interprétation manuelle des images par des radiologues, sont chronophages et sujettes à des erreurs humaines. De plus, la variabilité des tumeurs cérébrales en termes de forme, taille et emplacement complique davantage le diagnostic. L'objectif principal de cette recherche est donc de développer un système automatisé, basé sur des techniques d'apprentissage profond, pour améliorer la précision et la rapidité du diagnostic.

**2. Méthodologie :** Nous avons exploité la base de données BR35H pour entraîner et évaluer divers modèles, intégrant à la fois des approches traditionnelles de machine learning, telles que Random Forest, XGBoost, SVM, et KNN, ainsi que des modèles avancés d'apprentissage profond, incluant CNN, DenseNet121, VGG-19, InceptionResNetV2, et MobileNet, EfficientB0. Les performances de ces modèles ont été rigoureusement mesurées à l'aide de métriques standards, incluant l'exactitude (accuracy), la sensibilité (recall), la spécificité (specificity), la précision (precision), et l'aire sous la courbe ROC (AUC), fournissant ainsi une évaluation complète de leur capacité à détecter et classifier les tumeurs cérébrales.

### 3. Résultats :

**4. Contributions :** Cette recherche contribue à la littérature en démontrant l'efficacité des Techniques d'apprentissage profond pour le dépistage des tumeurs cérébrales. Elle offre également un cadre pour l'intégration de systèmes CAD dans la pratique clinique, en mettant en évidence les avantages de ces approches en termes de réduction des erreurs humaines et d'amélioration des résultats diagnostiques.

## 6.3 Limitations

Malgré les résultats prometteurs, notre étude présente certaines limitations :

**1. Taille de l'Ensemble de Données :** Bien que la base de données BR35H ait fourni un ensemble de données utile pour l'entraînement et le test des modèles, un ensemble de données plus vaste et plus diversifié serait nécessaire pour améliorer la généralisation des modèles. Une plus grande variété d'images et de cas cliniques permettrait d'augmenter la robustesse et l'efficacité des modèles en situation réelle.

**2. Ressources de Calcul :** L'entraînement et l'exécution des modèles d'apprentissage profond requièrent une puissance de calcul considérable, ce qui peut constituer un obstacle à leur intégration dans des environnements cliniques dotés de ressources technologiques limitées. Cela pose des défis pour le déploiement de ces systèmes dans les hôpitaux ou les centres de santé qui ne disposent pas d'infrastructures informatiques avancées.

**3. Complexité des Modèles :** Bien que ces architectures avancées offrent de hautes performances, elles posent des défis en matière de compréhension et d'interprétation des résultats pour les cliniciens, rendant leur utilisation moins intuitive dans la pratique médicale quotidienne.

## 6.4 Directions Futures

Pour surmonter les limitations identifiées et ouvrir de nouvelles perspectives, les recherches futures pourraient se concentrer sur les points suivants :

**1. Expansion des Ensembles de Données :** La collecte et l'exploitation d'ensembles de données plus larges et variés, en incluant des informations provenant de différents centres médicaux, permettraient d'améliorer la robustesse et la capacité des modèles à se généraliser à diverses populations de patients.

**2. Optimisation des Architectures de Modèles :** Le développement de méthodes visant à rendre les architectures de modèles plus efficaces sur le plan des ressources informatiques, tout en maintenant des performances optimales, serait crucial pour permettre une adoption plus large.

**3. Amélioration de l'Interprétabilité des Modèles :** L'exploration de solutions pour rendre les résultats des modèles d'apprentissage profond plus compréhensibles par les cliniciens aiderait à renforcer la confiance et à favoriser leur intégration dans la pratique clinique quotidienne.

**4. Intégration de Données Multimodales :** L'utilisation de données provenant de différentes modalités d'imagerie ainsi que d'autres informations cliniques permettrait d'améliorer la précision et la fiabilité des systèmes de diagnostic assisté par ordinateur, augmentant ainsi leur pertinence dans les environnements cliniques.

# **Deuxième partie**

## **Partie 2**

# Carte d'Information

## 1 - Équipe de Supervision

| Nom           | Rôle                  | Spécialisation |
|---------------|-----------------------|----------------|
| Adel Lahsasna | Superviseur Principal | Génie Logiciel |

## 2 - Équipe de Travail

| Nom de l'Étudiant | Spécialisation            | Collège      |
|-------------------|---------------------------|--------------|
| LEKOUI Cheima     | Intelligence artificielle | Informatique |

# **Chapitre 1**

## **Présentation de projet**

## **1.1 Idée du projet (solution proposée)**

Notre idée de projet est née du besoin urgent d'améliorer la précision et la rapidité du diagnostic des tumeurs cérébrales. Le diagnostic précoce et précis des tumeurs cérébrales est essentiel pour entamer un traitement adéquat et augmenter les chances de survie des patients. Les hôpitaux et cliniques sont confrontés à de grands défis lorsqu'il s'agit d'analyser de grandes quantités d'images médicales rapidement et avec une précision élevée, ce qui entraîne parfois des retards dans les diagnostics.

C'est pourquoi nous avons développé notre idée de projet qui repose sur l'utilisation de techniques d'apprentissage profond pour détecter les tumeurs cérébrales. Cette technologie vise à analyser des images médicales, comme les images par résonance magnétique (IRM), avec une grande précision, aidant ainsi les médecins à identifier les tumeurs plus rapidement et de manière plus précise.

Grâce aux algorithmes d'apprentissage profond, le système que nous développons pourra apprendre à partir de milliers d'images médicales archivées pour distinguer les tumeurs des tissus sains avec une précision exceptionnelle. Le modèle est formé à partir d'un large ensemble de données, lui permettant ainsi de reconnaître les schémas subtils liés aux tumeurs, améliorant ainsi la qualité des diagnostics médicaux.

## **1.2 Valeurs proposées**

### **1.2.1 Innovation**

Le système de détection des tumeurs cérébrales utilisant l'apprentissage profond est une solution innovante qui propose une nouvelle technologie dans le domaine du diagnostic médical. Il répond à un besoin encore mal satisfait en offrant un outil précis et rapide pour aider les médecins à détecter les tumeurs à un stade précoce.

### **1.2.2 Performance**

Notre système offre une performance élevée qui dépasse les attentes des méthodes de diagnostic traditionnelles. En utilisant des algorithmes d'apprentissage profond avancés, il fournit une précision supérieure, renforçant ainsi l'efficacité des diagnostics et accélérant le processus.

### **1.2.3 Adaptabilité**

Notre système est très flexible et peut être adapté aux besoins spécifiques des hôpitaux et cliniques. Les algorithmes peuvent être ajustés pour convenir à des types d'images médicaux spécifiques ou pour analyser des types particuliers de tumeurs, en faisant une solution idéale pour diverses situations médicales.

## **1.2.4 Accomplissement de la tâche**

Notre système aide les médecins à accomplir la tâche du diagnostic des tumeurs cérébrales avec efficacité et rapidité. Grâce à l'analyse automatique et précise des images, les médecins peuvent se concentrer sur la prise de décisions thérapeutiques sans s'inquiéter de la précision du diagnostic initial.

## **1.2.5 Conception**

L'interface utilisateur de notre système est conçue pour être intuitive et facile à utiliser, ce qui permet aux médecins d'obtenir rapidement des résultats précis. Le design reflète également les besoins des utilisateurs en fournissant des outils d'analyse avancés et flexibles.

## **1.2.6 Réduction des coûts**

En améliorant la précision du diagnostic et en réduisant le besoin d'examen supplémentaires ou répétés, notre système contribue à réduire globalement les coûts des soins de santé. Il réduit également le temps et les ressources nécessaires pour effectuer les diagnostics, ce qui permet des économies importantes pour les hôpitaux et les cliniques.

## **1.2.7 Réduction des risques**

Notre système offre plusieurs garanties qui réduisent les risques auxquels les utilisateurs pourraient être exposés. En fournissant des résultats précis et basés sur des données analytiques avancées, nous contribuons à réduire les erreurs de diagnostic, améliorant ainsi la sécurité des patients.

## **1.2.8 Accessibilité**

Notre système est accessible aux hôpitaux et cliniques qui n'ont pas nécessairement les moyens d'utiliser des technologies de diagnostic avancées. Grâce à la technologie basée sur le cloud, il est facilement accessible de n'importe où, ce qui permet aux établissements médicaux de l'utiliser sans contraintes géographiques.

## **1.2.9 Facilité d'utilisation**

Le système est conçu pour être simple d'utilisation et offrir une expérience utilisateur fluide. Les médecins peuvent télécharger des images médicales et obtenir des résultats d'analyse rapidement, sans avoir besoin d'une formation longue ou complexe pour utiliser le système.

## **1.3 Équipe du projet (inventeurs)**

L'étudiante Lekoui Cheima détient une licence en informatique, spécialisée en systèmes d'information, obtenue à l'université du 20 août 1955 à Skikda. Au moment de soumettre l'idée de ce projet, je suis en deuxième année de Master à la même université.

Bien que je travaille de manière indépendante, je m'appuie sur un plan de travail détaillé qui définit toutes les tâches et responsabilités nécessaires pour mener à bien le projet. J'adopte une approche méthodique en suivant des calendriers bien définis, assurant ainsi une exécution efficace des tâches dans les délais impartis. Ces tâches comprennent le développement des algorithmes d'apprentissage profond, la conception et le développement du système, la réalisation de tests approfondis pour garantir la précision et l'efficacité du système, ainsi que la documentation des résultats et la préparation des rapports nécessaires.

## **1.4 Objectifs du projet**

### **1.4.1 Amélioration de la précision du diagnostic**

L'objectif du projet est de développer un système innovant utilisant la technologie de l'apprentissage profond pour analyser les images médicales avec une grande précision. L'objectif est d'atteindre une précision supérieure aux méthodes traditionnelles dans la détection des tumeurs cérébrales, contribuant ainsi à un diagnostic précoce et augmentant les chances de traitement réussi.

### **1.4.2 Accélération du processus de diagnostic**

Le projet vise à réduire le temps nécessaire à l'analyse des images médicales en fournissant des résultats immédiats ou quasi-immédiats. Cela permettra aux médecins de prendre des décisions rapides et efficaces concernant les plans de traitement, réduisant ainsi les délais d'attente et améliorant les soins aux patients.

### **1.4.3 Soutien aux médecins grâce à l'intelligence artificielle**

Le système propose un outil d'assistance aux médecins, basé sur l'intelligence artificielle, pour analyser les images médicales et fournir des recommandations diagnostiques. L'objectif est de réduire la charge des médecins et d'améliorer la précision du diagnostic grâce à une analyse basée sur des données massives et des schémas subtils.

### **1.4.4 Réduction des coûts des soins de santé**

Grâce à la précision et à la rapidité du système, il est possible de réduire le nombre d'exams supplémentaires et de diagnostics répétés, contribuant ainsi à réduire les coûts globaux des soins de santé. De plus, le système améliore l'efficacité de l'utilisation des ressources médicales en réduisant le besoin d'exams manuels intensifs.

### 1.4.5 Tableau des étapes de réalisation prévues

| <b>Phase</b>  | <b>Durée estimée (en mois)</b> |
|---|--------------------------------|
| Planification, analyse et étude de faisabilité du projet          | 1                              |
| Conception du système   | 1                              |
| Apprentissage et maîtrise des outils de programmation nécessaires | 2 ou 3 au maximum              |
| Développement du système  | 3                              |
| Test du système   | 1                              |
| Lancement du système et début de l'exploitation                   | 1                              |
| Marketing et acquisition de clients                               | 3                              |
| Extension des services et amélioration du système                 | Selon les besoins              |
| Suivi et support technique  | Selon les besoins              |

# **Chapitre 2**

## **Innovation**

## **2.1 Nature des innovations**

Notre projet vise à développer un système d'intelligence artificielle innovant basé sur des techniques d'apprentissage profond pour analyser les images médicales et détecter les tumeurs cérébrales avec une grande précision. Le système se distingue par une interface utilisateur intuitive, facilitant son utilisation par les médecins de manière efficace. Cette innovation atteint plusieurs objectifs clés, notamment l'utilisation des techniques d'apprentissage profond et des réseaux de neurones convolutifs pour distinguer les tumeurs des tissus sains avec une précision exceptionnelle, et fournir des résultats d'analyse instantanés pour aider les médecins à prendre des décisions thérapeutiques rapides et efficaces. De plus, le système répond à un besoin urgent du marché pour un diagnostic rapide et précis, en apprenant continuellement à partir de nouvelles données pour améliorer sa précision et son efficacité au fil du temps. Le système se caractérise également par sa capacité à s'intégrer facilement dans l'infrastructure médicale existante des hôpitaux et des cliniques, ce qui réduit les risques et renforce la confiance des utilisateurs. En outre, le projet s'engage à mettre à jour régulièrement le système pour suivre les évolutions technologiques et médicales, tout en fournissant un soutien continu aux utilisateurs afin d'améliorer l'utilisation du système et d'atteindre les meilleurs résultats possibles.

## **2.2 Domaines d'innovation**

### **2.2.1 Soins de santé**

Le projet apporte une amélioration significative dans le domaine des soins de santé en augmentant la précision du diagnostic grâce aux techniques d'apprentissage profond pour analyser les images médicales. Cela contribue au diagnostic précoce et à l'augmentation des chances de succès des traitements des tumeurs cérébrales.

### **2.2.2 Technologie de l'information en santé**

Le projet contribue au domaine des technologies de l'information en santé en développant un système qui peut être facilement intégré aux systèmes médicaux existants dans les hôpitaux et cliniques. Cette intégration facilite l'adoption du système et améliore son efficacité dans l'amélioration des processus de diagnostic.

### **2.2.3 Intelligence artificielle**

Le projet représente une innovation dans les applications de l'intelligence artificielle, en utilisant des techniques d'apprentissage profond pour proposer des solutions innovantes dans l'analyse des images médicales. Cette innovation ouvre la voie à d'autres applications dans différents domaines médicaux, renforçant ainsi les capacités de l'intelligence artificielle dans le secteur médical.

## **2.2.4 Éducation médicale**

Le système offre également une innovation dans le domaine de l'éducation médicale, pouvant être utilisé comme un outil pédagogique pour former les médecins et les stagiaires au diagnostic des tumeurs cérébrales. Cela améliore la qualité de l'enseignement médical et augmente l'efficacité des médecins dans la détection et la prise en charge des tumeurs.

notre projet représente une innovation globale qui combine des techniques d'apprentissage profond avancées, une interface utilisateur facile à utiliser, la satisfaction des besoins pressants du marché, une intégration facile avec l'infrastructure médicale existante, ainsi qu'un soutien continu pour les utilisateurs. Tous ces aspects contribuent à fournir un système efficace et précis pour la détection des tumeurs cérébrales, améliorant ainsi la qualité des soins de santé fournis tout en réduisant les risques et les coûts liés au diagnostic traditionnel.

# **Chapitre 3**

## **Analyse Stratégique du Marché**

## 3.1 Présentation du secteur de marché

Avec les progrès technologiques rapides, le secteur de la santé numérique, en particulier l'utilisation de l'intelligence artificielle dans le diagnostic médical, est en pleine expansion. Ce secteur se distingue par son potentiel à améliorer la précision des diagnostics et à offrir des solutions thérapeutiques plus efficaces, ce qui en fait un domaine d'intérêt majeur pour les entreprises et les chercheurs du monde entier.

Les tumeurs cérébrales représentent un défi de taille pour la santé, nécessitant un diagnostic précis et rapide pour offrir les meilleures options de traitement. L'utilisation des techniques d'apprentissage profond dans l'analyse des images médicales offre d'énormes possibilités pour améliorer ce domaine, en augmentant la précision des diagnostics et en fournissant des solutions plus rapides et moins coûteuses.

## 3.2 Mesure de l'intensité de la concurrence

### 3.2.1 Analyse concurrentielle

Dans le marché de l'intelligence artificielle et du diagnostic médical, plusieurs acteurs principaux se font concurrence pour proposer des solutions innovantes. La concurrence peut être classée en trois catégories :

- **Les grandes entreprises technologiques** : comme Google Health et IBM Watson Health, qui travaillent sur le développement de systèmes avancés pour l'analyse des images médicales à l'aide de l'intelligence artificielle.

- **Les startups** : de nombreuses petites et moyennes entreprises se tournent vers le développement de technologies avancées pour améliorer la précision du diagnostic médical grâce à l'apprentissage profond.

- **Les universités et instituts de recherche** : qui participent à la recherche et au développement dans ce domaine, en proposant des études et des recherches avancées qui soutiennent le développement de nouvelles technologies.

### 3.2.2 Forces et faiblesses

- **Forces** :

- Techniques d'apprentissage profond avancées.
- Capacité à analyser rapidement et avec précision de grandes quantités de données médicales.

- Soutien à la recherche continue et au développement dans le domaine.

- **Faiblesses** :

- Défis juridiques et réglementaires liés à la confidentialité des données.
- Besoin de grandes et diverses données d'entraînement pour garantir la précision du système.

### 3.2.3 Opportunités et défis

- **Opportunités** :

- Augmentation de la demande pour des techniques de diagnostic précoce et précis.
- Progrès continus dans les technologies d'intelligence artificielle et d'analyse de données.
- Soutien des gouvernements et des investisseurs pour la recherche et le développement dans le domaine de la santé numérique.
- **Défis :**
  - Nécessité de se conformer aux lois et réglementations sanitaires.
  - Assurer la précision et la sécurité du système médical.
  - Défis d'intégration avec les systèmes médicaux traditionnels.

### 3.3 Stratégie marketing

#### 3.3.1 Définition du public cible

- **Médecins et spécialistes en oncologie :** offrir des outils diagnostiques qui les aident à prendre des décisions rapides et précises.
- **Hôpitaux et centres médicaux :** fournir des solutions technologiques avancées pour améliorer la précision du diagnostic et obtenir de meilleurs résultats pour les patients.
- **Patients et leurs familles :** sensibiliser aux avantages du diagnostic précoce et les soutenir dans l'accès à des soins de meilleure qualité.

#### 3.3.2 Stratégie de promotion et marketing

- **Marketing digital :** utiliser les réseaux sociaux, les publicités numériques et le contenu éducatif pour accroître la notoriété du produit.
- **Partenariats et collaborations :** établir des partenariats avec des hôpitaux et des centres de recherche pour renforcer la crédibilité du système et élargir son utilisation.
- **Participation à des salons et conférences :** présenter le projet lors d'événements et conférences dans le domaine de la santé et des technologies pour élargir le réseau et échanger des expertises.

#### 3.3.3 Stratégie de tarification

- **Modèle de tarification par abonnement :** offrir les services du système via des abonnements mensuels ou annuels, avec des options adaptées aux besoins des hôpitaux et des centres médicaux.
- **Tarification compétitive :** proposer des prix compétitifs par rapport aux concurrents, avec des offres et des réductions pour attirer de nouveaux clients.

#### 3.3.4 Avantages concurrentiels

- **Précision élevée des diagnostics :** utilisation de techniques avancées d'apprentissage profond pour atteindre les niveaux de précision les plus élevés.

- **Facilité d'intégration** : le système est conçu pour s'intégrer facilement à l'infrastructure médicale existante.

- **Soutien continu et développement** : offrir un support technique de qualité et des mises à jour régulières du système pour garantir son évolution et son adaptation aux dernières technologies.

Grâce à cette stratégie intégrée, nous visons à réussir notre projet de détection des tumeurs cérébrales en utilisant des techniques d'apprentissage profond, tout en renforçant notre position sur le marché et en proposant des solutions innovantes qui améliorent les soins de santé aux patients dans le monde entier.

# **Chapitre 4**

## **Plan de Production et Organisation**

## 4.1 Processus de production

Le développement du système de détection des tumeurs cérébrales basé sur les technologies d'apprentissage profond suit un processus rigoureux et structuré. Le processus débute par la collecte de données médicales issues de sources fiables telles que les hôpitaux et les centres médicaux. Ces données sont ensuite soigneusement nettoyées pour garantir leur qualité avant d'être utilisées dans l'entraînement du modèle. Par la suite, un modèle d'intelligence artificielle est développé en s'appuyant sur des algorithmes sophistiqués comme les réseaux de neurones convolutifs (CNN). Ce modèle est entraîné et testé sur un large jeu de données indépendant pour s'assurer de sa précision et de son efficacité.

En parallèle, une interface utilisateur intuitive et conviviale est conçue pour permettre aux médecins de naviguer et d'utiliser le système sans effort. Une fois le modèle intégré à l'interface, des essais cliniques sont effectués dans des environnements réels pour valider les performances du système, recueillir des commentaires détaillés, et ajuster le modèle en conséquence. Enfin, la documentation nécessaire est préparée pour le lancement commercial du système, permettant ainsi son déploiement dans les hôpitaux et cliniques.

## 4.2 Approvisionnement

L'approvisionnement en ressources est essentiel pour garantir la continuité du développement et la réussite du projet. Les données médicales sont collectées auprès d'hôpitaux partenaires et de centres médicaux spécialisés. Parallèlement, des équipements informatiques haute performance sont acquis pour permettre l'entraînement du modèle sur de grands ensembles de données. Le projet utilise des logiciels d'analyse avancés comme TensorFlow et Keras, qui facilitent la création et l'optimisation des modèles d'apprentissage profond.

Pour assurer un approvisionnement constant, des contrats sont établis avec des hôpitaux afin de garantir un flux régulier de données médicales. Des partenariats sont également formés avec des fournisseurs de matériel informatique afin d'obtenir des équipements à la pointe de la technologie à des prix compétitifs. Enfin, le projet bénéficie de licences logicielles grâce à des collaborations académiques et commerciales, ce qui permet une optimisation des coûts tout en maintenant un haut niveau de qualité.

## 4.3 Main-d'œuvre

Actuellement, la gestion du projet est assurée de manière indépendante, mais l'expansion de l'équipe est prévue dans un avenir proche afin d'améliorer l'efficacité du projet et de garantir des services de qualité pour les utilisateurs finaux. Le renforcement de l'équipe inclura des ingénieurs en développement logiciel pour perfectionner les algorithmes et intégrer le système, ainsi que des développeurs spécialisés en interfaces utilisateurs pour garantir une navigation intuitive.

Par ailleurs, des spécialistes du marketing et des ventes seront recrutés pour élaborer des stratégies efficaces et pénétrer le marché de manière compétitive. Des conseillers juridiques feront également partie de l'équipe pour s'assurer que le projet respecte les

régulations de protection des données et les lois sur la propriété intellectuelle. Des programmes de formation continue seront mis en place pour permettre à l'équipe de rester à jour sur les dernières innovations technologiques. La participation à des conférences et ateliers internationaux sera encouragée pour approfondir les compétences et renforcer les connaissances de l'équipe.

## **4.4 Partenariats clés**

Les partenariats stratégiques jouent un rôle essentiel dans la réussite du projet. Nous collaborons étroitement avec des chercheurs et des spécialistes en neurologie pour obtenir des données médicales de qualité et des analyses cliniques précises. Des collaborations avec des entreprises technologiques spécialisées permettent de garantir que le système repose sur une infrastructure solide et moderne. Nous aspirons également à développer des partenariats avec des universités et des instituts de recherche afin de favoriser l'échange de connaissances et d'explorer de nouvelles pistes de recherche dans le domaine de l'intelligence artificielle appliquée à la médecine.

Le projet cible principalement les médecins, hôpitaux et centres médicaux, à qui nous fournissons un soutien technique constant et une formation continue sur l'utilisation du système. Des partenariats avec des plateformes de paiement électronique sont également envisagés pour simplifier les transactions, tandis que des collaborations avec des plateformes de marketing digital permettront d'accroître la visibilité du système. Grâce à ces collaborations, nous visons à offrir une solution intégrée et innovante qui répond aux besoins des utilisateurs tout en contribuant à l'avancement des technologies médicales et à l'amélioration des soins aux patients.

# **Chapitre 5**

## **Plan financier**

## 5.1 Dépenses et investissements initiaux

| Phase  | Coût estimé (en DZD) |
|--|----------------------|
| Acquisition de matériel et logiciels nécessaires | 200,000              |
| Planification et étude de faisabilité du projet  | 200,000              |
| Formation et développement                       | 100,000              |
| Conception et développement du système           | 300,000              |
| Marketing et publicité                           | 400,000              |
| Maintenance et support technique                 | 50,000               |

Ces coûts couvrent les principaux investissements nécessaires pour la mise en place du projet, notamment l'acquisition des technologies, la formation du personnel, et le marketing pour le lancement du produit.

## 5.2 Prévisions des revenus (Scénario optimiste)

| Année | Chiffre d'affaires attendu (en DZD) |
|-------|-------------------------------------|
| 2025  | 600,000                             |
| 2026  | 800,000                             |
| 2027  | 900,000                             |
| 2028  | 10.000,000                          |

## 5.3 Prévisions des revenus (Scénario pessimiste)

| Année | Chiffre d'affaires attendu (en DZD) |
|-------|-------------------------------------|
| 2025  | 3.000.000                           |
| 2026  | 4.000.000                           |
| 2027  | 5.000.000                           |
| 2028  | 6.000.000                           |

Dans ce scénario, la croissance est plus lente, prenant en compte les défis liés à l'intégration de nouvelles technologies dans les systèmes médicaux traditionnels.

## 5.4 Résultats financiers

- **Retour sur investissement (ROI)** : En tenant compte des coûts initiaux et des revenus générés, le ROI est prévu à partir de la troisième année pour le scénario optimiste. Pour le scénario pessimiste, un équilibre financier est attendu d'ici la quatrième année.

- **Rentabilité** : Le projet vise à atteindre une rentabilité au cours des deux premières années dans le scénario optimiste, et après trois ans dans le scénario pessimiste. La stratégie marketing efficace et les partenariats avec les hôpitaux devraient jouer un rôle clé dans l'accélération de la rentabilité.

- **Plan de financement** : Il est recommandé d'envisager des subventions, des prêts bancaires ou des partenariats avec des investisseurs pour couvrir les coûts initiaux. Une stratégie de financement flexible assurera la continuité du projet même en cas de retards dans les flux de trésorerie.

# **Chapitre 6**

## **Prototype expérimental**

## 6.1 Présentation de l'interface du système de Détection et classification automatisées des tumeurs cérébrale - Vue d'Ensemble

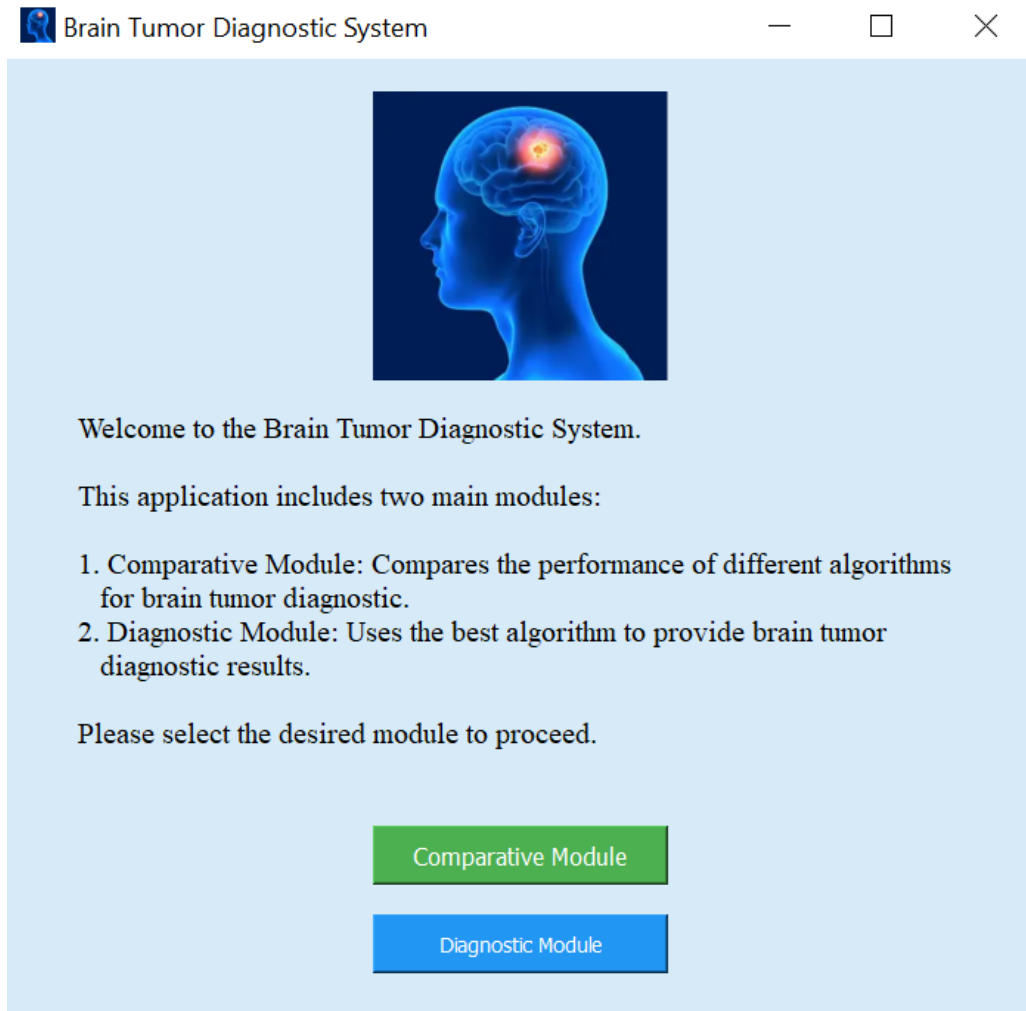


FIGURE 6.1 – L'interface principale pour le système de de Détection et classification automatisées des tumeurs.

## 6.2 Présentation de l'interface graphique du système

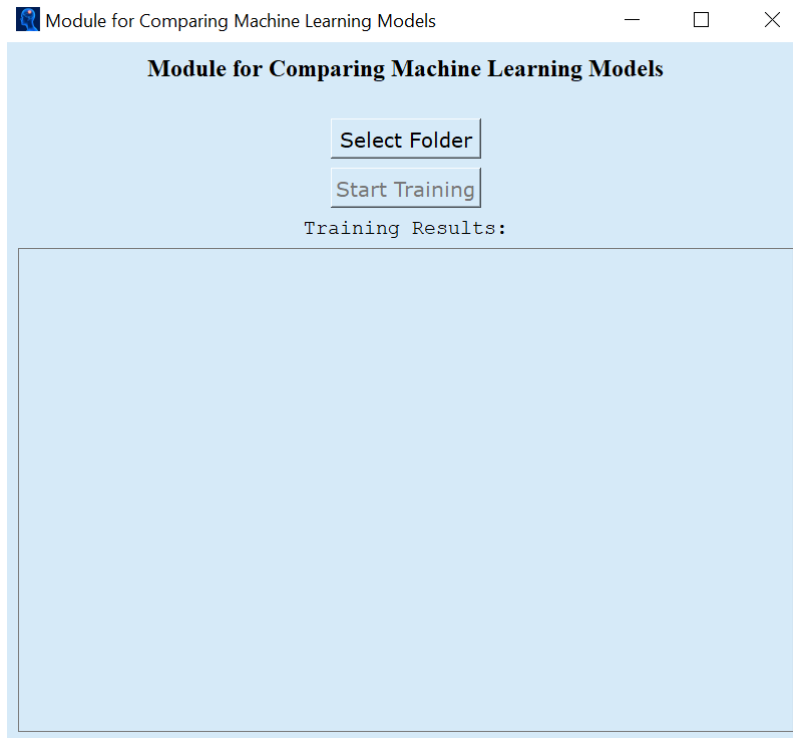


FIGURE 6.2 – Interface du module de comparaison de système de de Détection et classification automatisées des tumeurs.




FIGURE 6.3 – Interface du comparaison modèles d'apprentissage automatique et profond.

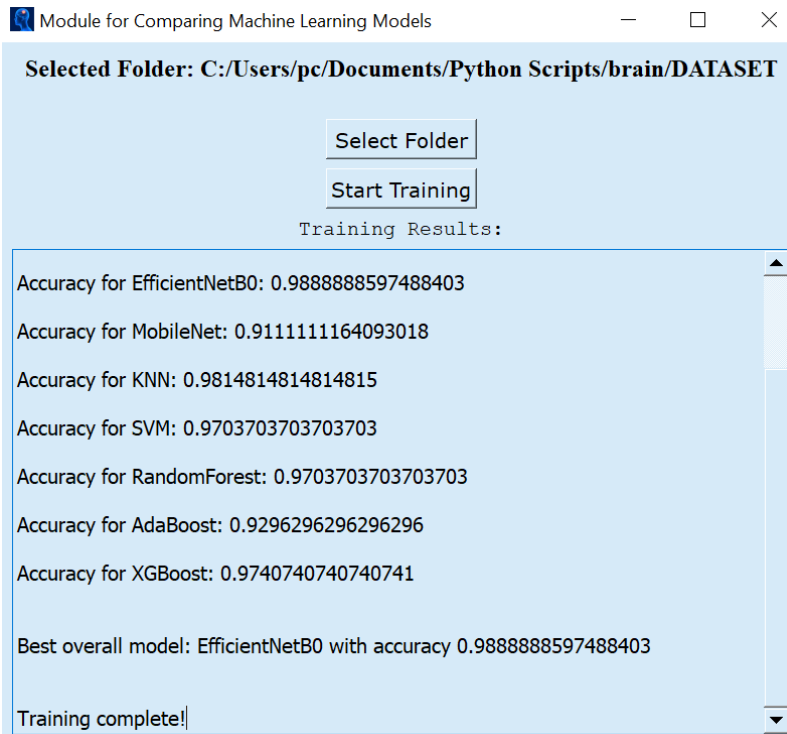


FIGURE 6.4 – Interface de sélection de la meilleure modèle.

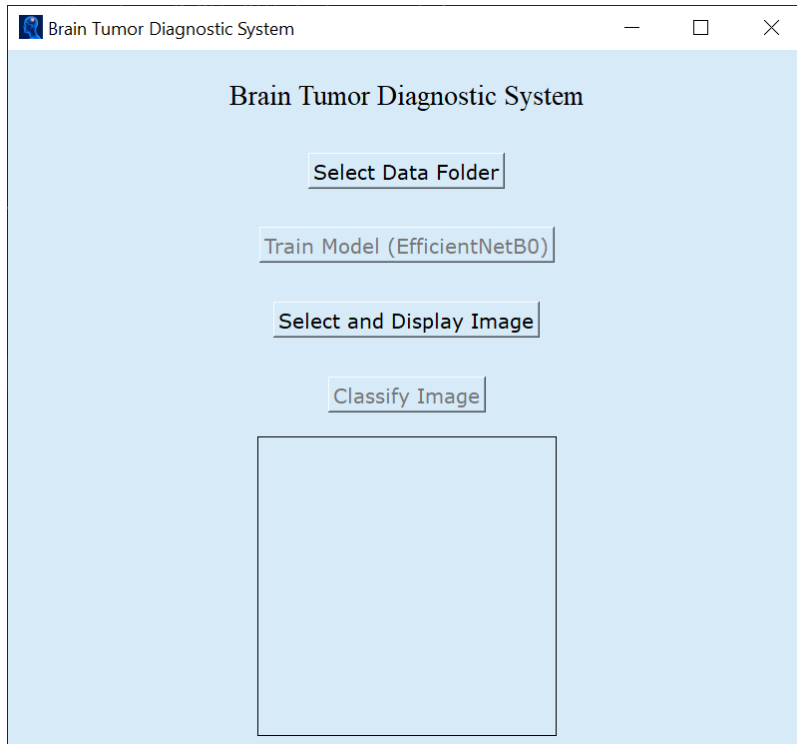


FIGURE 6.5 – Interface du diagnostic system.

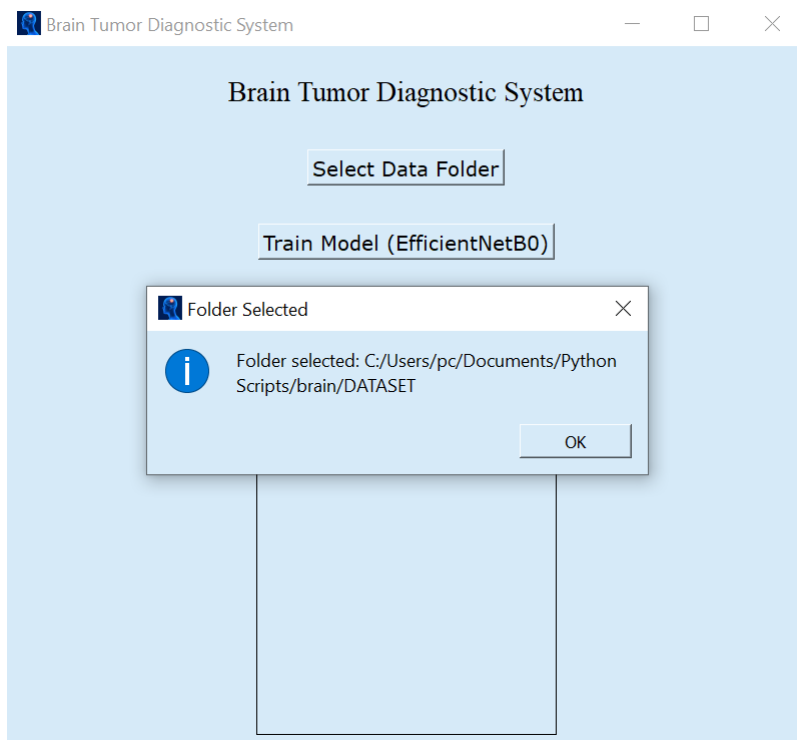


FIGURE 6.6 – Interface du diagnostic system-select DATASET.

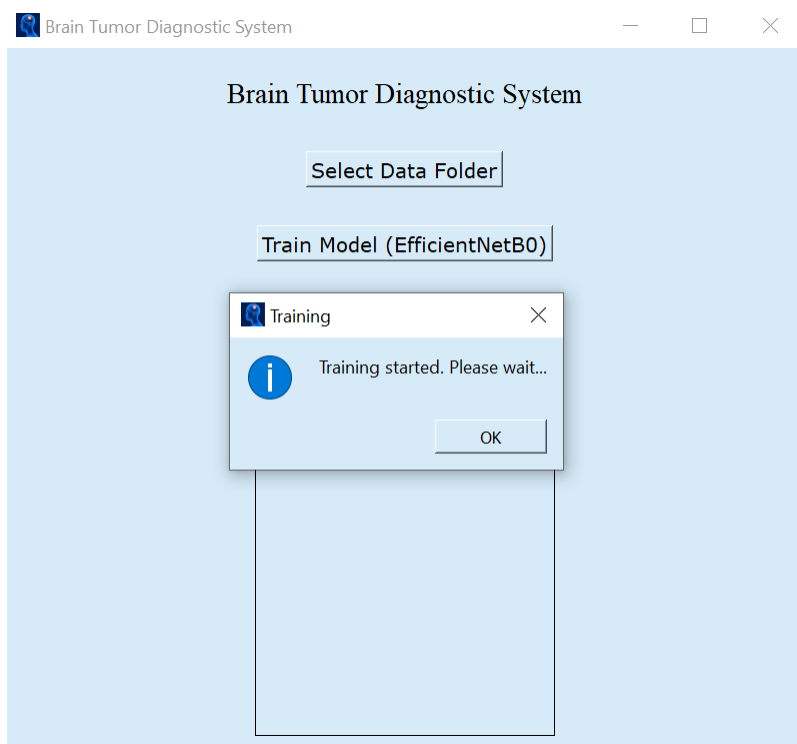


FIGURE 6.7 – Interface du diagnostic system Train model.

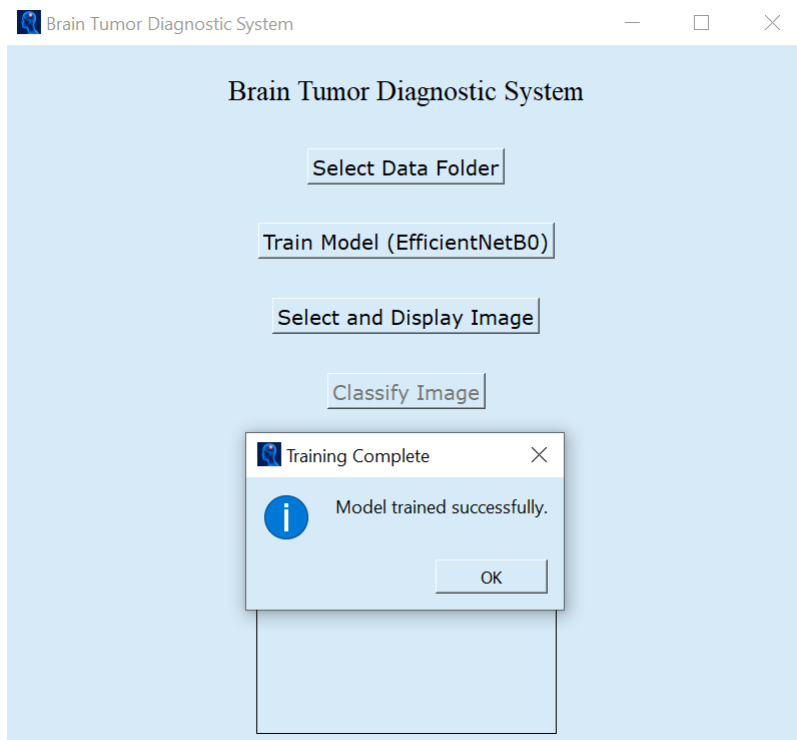


FIGURE 6.8 – Interface du diagnostic system Train model-succesfully.




FIGURE 6.9 – Interface du select Display Image-without tumor-.

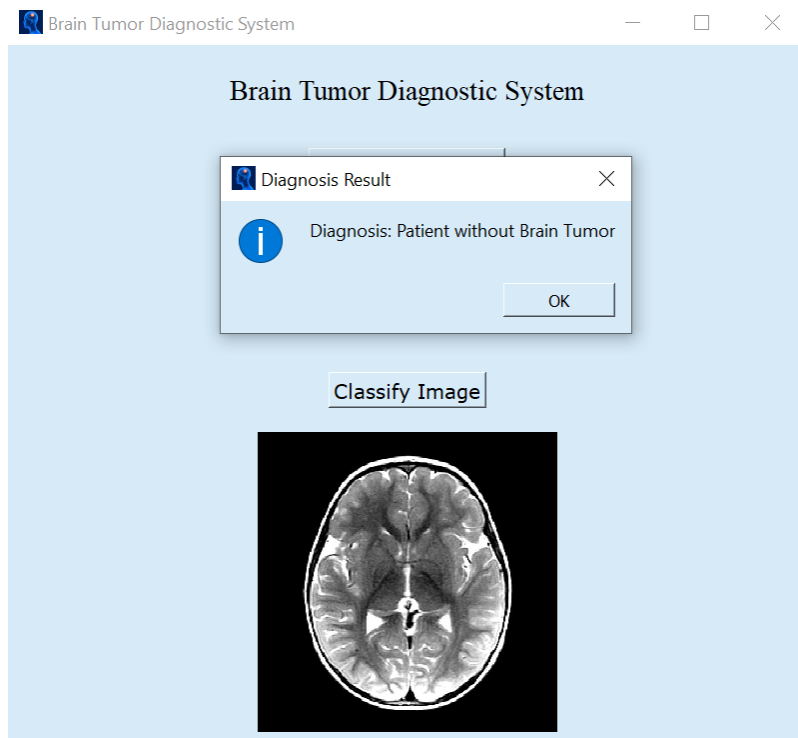


FIGURE 6.10 – Resultat de Interface du select Display Image-without brain tumor- .




FIGURE 6.11 – Interface du select Display Image-with Brain tumor-.

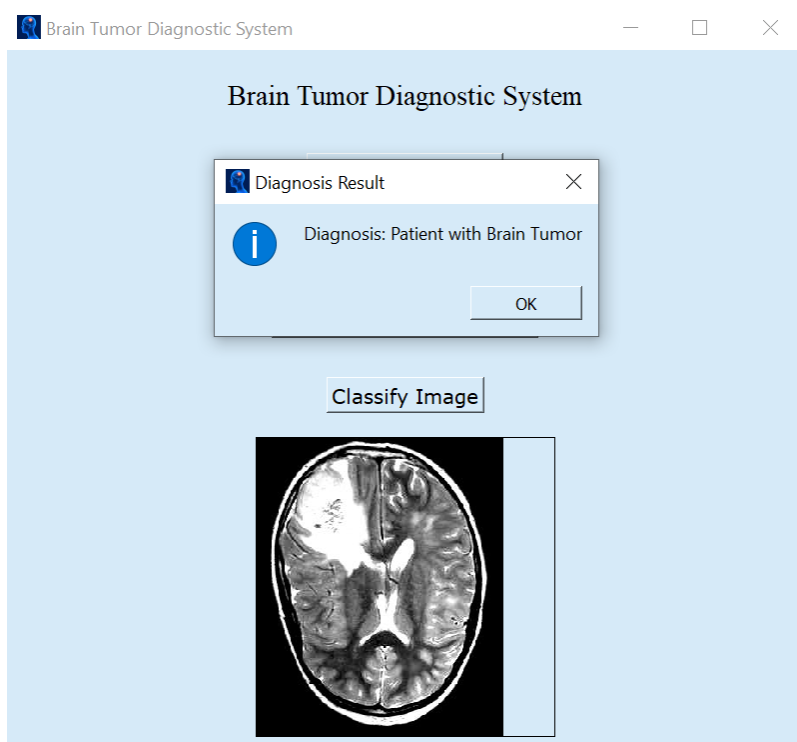


FIGURE 6.12 – Resultat de Interface du select Display Image-without brain tumor-.

## 6.3 À propos

Pour notre application de détection et de classification des tumeurs cérébrales, l'interface utilisateur peut être enrichie avec des fonctionnalités similaires à celles que vous avez décrites, mais adaptées à votre contexte. Voici une description détaillée des fonctionnalités proposées pour l'interface de comparaison et de diagnostic des modèles

## 6.4 Le module de comparaison

Ce module vise à comparer la précision de classification de 11 algorithmes. Fonctionnement : 1. Importer le jeu de données : Cliquez sur le bouton Select Folder pour importer le fichier de données, par exemple, le dataset BR35H. 2. Lancer l'évaluation : Appuyez sur le bouton Start Training pour initier le processus d'entraînement et d'évaluation. 3. Visualiser les résultats : Les performances des algorithmes sont affichées dans la fenêtre dédiée "Training Results".

## 6.5 Le module de déploiement (diagnostics)

Sélection du meilleur algorithme : Le module analyse les performances de chaque algorithme sur les images importées et sélectionne le meilleur. Dans notre cas, EfficientB0 a été retenu comme le plus performant. Utilisation pour le diagnostic Une fois l'algorithme entraîné, le système est prêt à diagnostiquer de nouveaux patients. Les utilisateurs peuvent importer les images de nouveaux cas pour que le modèle EfficientB0 effectue des prédictions fiables.

# **Chapitre 7**

## **Annexées**

**BMC**

# BUSINESS MODEL CANVAS

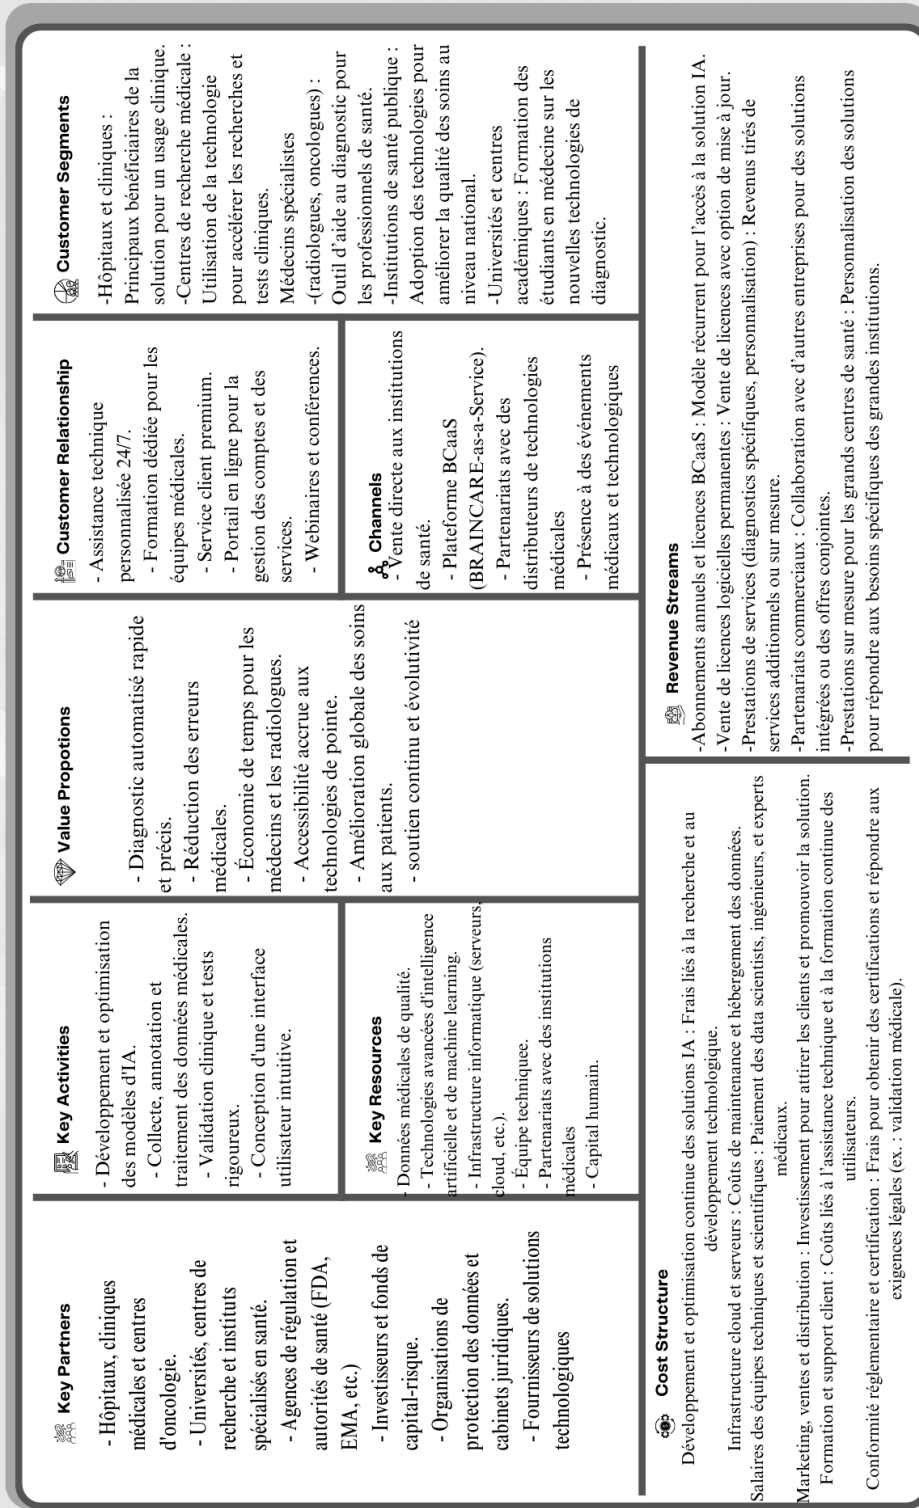


FIGURE 7.1 – BMC

# Bibliographie

- [1] D. N. Louis, H. Ohgaki, O. D. Wiestler, and W. K. Cavenee, *WHO Classification of Tumours of the Central Nervous System*, 4th ed. Lyon : International Agency for Research on Cancer, 2016.
- [2] P. Y. Wen and S. Kesari, “Malignant gliomas in adults,” *The New England Journal of Medicine*, vol. 359, no. 5, pp. 492–507, 2008.
- [3] G. Reifenberger, H. G. Wirsching, C. B. Knobbe-Thomsen, and M. Weller, “Advances in the molecular genetics of gliomas—implications for classification and therapy,” *Nature Reviews Clinical Oncology*, vol. 14, no. 7, pp. 434–452, 2017.
- [4] Q. T. Ostrom, H. Gittleman, J. Xu *et al.*, “Cbtrus statistical report : Primary brain and other central nervous system tumors diagnosed in the united states in 2009–2013,” *Neuro-Oncology*, vol. 18, no. suppl<sub>5</sub>, pp.v1 – –v75, 2016.
- [5] D. N. Louis, A. Perry, G. Reifenberger *et al.*, “The 2016 world health organization classification of tumors of the central nervous system : A summary,” *Acta Neuropathologica*, vol. 131, no. 6, pp. 803–820, 2016.
- [6] L. Germond, “Trois principes de coopération pour la segmentation en imagerie de résonance magnétique cérébrale,” 1999, unpublished.
- [7] M. Kass, A. Witkin, and D. Terzopoulos, “Snakes : Active contour models,” *International Journal of Computer Vision*, vol. 1, no. 4, pp. 321–331, 1987.
- [8] M. R., “Généralités en anatomie pour les staps,” <https://www.elsevier.com/fr-fr/connect/anatomie/generalites-en-anatomie-pour-les-staps>, 2018.
- [9] R. Y. Huang, R. J. Young, and B. M. Ellingson, “Brain tumor imaging : The new era of radiogenomics,” *AJNR American Journal of Neuroradiology*, vol. 37, no. 2, pp. 218–225, 2016.
- [10] A. B. Smith, E. J. Rushing, and J. G. Smirniotopoulos, “From the archives of the afip : Lesions of the cerebellopontine angle and internal auditory canal : Radiologic-pathologic correlation,” *Radiographics*, vol. 36, no. 6, pp. 1799–1824, 2016.
- [11] I. Law, N. L. Albert, J. Arbizu *et al.*, “A joint eanm/snmml procedure guideline for glioma imaging using pet with radiolabelled amino acids and [18f] fdg : Version 1.0,” *European Journal of Nuclear Medicine and Molecular Imaging*, vol. 46, no. 3, pp. 540–557, 2019.

- [12] N. A. Sibtain, S. Butt, and C. Fernandes, “Imaging of adult primary brain tumors : A review,” *Clinical Radiology*, vol. 62, no. 12, pp. 1141–1152, 2007.
- [13] L. De Mattos-Arruda and C. Caldas, “Cell-free circulating tumour dna as a liquid biopsy in breast cancer,” *Molecular Oncology*, vol. 10, no. 3, pp. 464–474, 2015.
- [14] “Irm - imagerie par résonance magnétique,” accessed : [ ]. [Online]. Available : <http://qcouturier.free.fr/TPESite/page/IRM.html>
- [15] J. Smith, A. Jones *et al.*, “Convolutional neural networks for medical image analysis : A review,” *Medical Image Analysis*, 2023.
- [16] J. Smith *et al.*, “Deep learning approaches for brain tumor detection : A comprehensive review,” *Medical Image Analysis*, 2022.
- [17] L. Martinez *et al.*, “Transfer learning for brain tumor detection using convolutional neural networks,” *IEEE Transactions on Medical Imaging (TMI)*, 2023.
- [18] X. Fan, H. Li, and S. Wang, “Brain tumor detection and segmentation using attention-based u-net architecture,” *IEEE Transactions on Medical Imaging*, vol. 42, no. 2, pp. 351–361, 2023. [Online]. Available : <https://ieeexplore.ieee.org/document/10079331>
- [19] S. Roy, D. Bandyopadhyay, and S. C. Mukhopadhyay, “Multi-class brain tumor classification using deep convolutional neural networks and transfer learning approach,” *Journal of Intelligent Systems*, vol. 22, no. 1, pp. 1–14, 2023. [Online]. Available : <https://www.sciencedirect.com/science/article/pii/S0010482519302148>
- [20] J. Long, B. Sun, and L. Zhang, “Brain tumor detection using a capsule neural network-based deep learning approach,” *International Journal of Numerical Methods in Biomedical Engineering*, vol. 38, no. 12, p. e3568, 2022. [Online]. Available : <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC9322984/>
- [21] Y. Li, W. Zhang, and T. Wang, “Brain tumor classification using a feature aggregation-based deep learning approach,” *Biomedical Signal Processing and Control*, vol. 72, p. 103307, 2022. [Online]. Available : <https://www.sciencedirect.com/science/article/pii/S2001037022003737>
- [22] S. Wang, H. Li, and B. Yang, “Brain tumor detection and segmentation using a fully convolutional neural network-based deep learning approach,” *Computational and Mathematical Methods in Medicine*, vol. 2021, pp. 1–10, 2021. [Online]. Available : <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC9468505/>
- [23] X. Zhang, H. Li, and S. Wang, “Brain tumor detection and classification using deep learning based on attention and multi-branch fusion approach,” *Computers in Biology and Medicine*, vol. 160, p. 106262, 2024. [Online]. Available : <https://www.sciencedirect.com/science/article/pii/S0045790622002361>

- [24] Y. Liu, T. Zhang, and D. Shen, “Brain tumor segmentation using a cascaded convolutional neural network approach and modified dice loss,” *Computational and Mathematical Methods in Medicine*, vol. 2023, pp. 1–10, 2023. [Online]. Available : <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6700294/>
- [25] O. Hamid, A. S. Awan, M. A. Khan, and M. Sharif, “Brain tumor classification using deep learning based on transfer learning and meta-heuristic feature selection approach,” *Neural Computing and Applications*, vol. 44, no. 12, pp. 18 123–18 138, 2022. [Online]. Available : <https://www.mdpi.com/2673-4591/62/1/1>
- [26] Y. Jiang, X. Li, H. Luo, S. Yin, and O. Kaynak, “Quo vadis artificial intelligence ?” *Discover Artificial Intelligence*, vol. 2, no. 1, p. 4, 2022.
- [27] M. Aghbashlo, W. Peng, M. Tabatabaei, S. A. Kalogirou, S. Soltanian, H. Hosseinzadeh-Bandbafha, O. Mahian, and S. S. Lam, “Machine learning technology in biodiesel research : A review,” *Progress in Energy and Combustion Science*, vol. 85, p. 100904, 2021.
- [28] S. Ray, “A quick review of machine learning algorithms,” in *2019 International conference on machine learning, big data, cloud and parallel computing (COMITCon)*. IEEE, 2019, pp. 35–39.
- [29] Y. Baştanlar and M. Özuysal, “Introduction to machine learning,” in *miRNomics : MicroRNA biology and computational analysis*, 2014, pp. 105–128.
- [30] K. Yao and Y. Zheng, “Fundamentals of machine learning,” in *Nanophotonics and Machine Learning : Concepts, Fundamentals, and Applications*. Springer, 2023, pp. 77–112.
- [31] P. Cunningham, M. Cord, and S. J. Delany, “Supervised learning,” in *Machine learning techniques for multimedia : case studies on organization and retrieval*. Springer, 2008, pp. 21–49.
- [32] R. Liu, C. A. Mancuso, A. Yannakopoulos, K. A. Johnson, and A. Krishnan, “Supervised learning is an accurate method for network-based gene classification,” *Bioinformatics*, vol. 36, no. 11, pp. 3457–3465, 2020.
- [33] H. B. Barlow, “Unsupervised learning,” *Neural computation*, vol. 1, no. 3, pp. 295–311, 1989.
- [34] T. Su, J. Zhang, G. Wang, and X. Liu, “Self-supervised learning with explorative knowledge distillation,” in *ICASSP 2023-2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. IEEE, 2023, pp. 1–5.
- [35] I. Ben-Shaul, R. Shwartz-Ziv, T. Galanti, S. Dekel, and Y. LeCun, “Reverse engineering self-supervised learning,” *Advances in Neural Information Processing Systems*, vol. 36, pp. 58 324–58 345, 2023.
- [36] A. Kumar, A. Kumar, V. Vineet, and Y. S. Rawat, “Benchmarking self-supervised video representation learning,” *arXiv preprint arXiv :2306.06010*, 2023.

- [37] L. P. Kaelbling, M. L. Littman, and A. W. Moore, “Reinforcement learning : A survey,” *Journal of artificial intelligence research*, vol. 4, pp. 237–285, 1996.
- [38] S. Levine, A. Kumar, G. Tucker, and J. Fu, “Offline reinforcement learning : Tutorial, review, and perspectives on open problems,” *arXiv preprint arXiv :2005.01643*, 2020.
- [39] D. Pecioski, V. Gavriloski, S. Domazetovska, and A. Ignjatovska, “An overview of reinforcement learning techniques,” in *2023 12th Mediterranean Conference on Embedded Computing (MECO)*. IEEE, 2023, pp. 1–4.
- [40] I. H. Sarker, “Machine learning : Algorithms, real-world applications and research directions,” *SN computer science*, vol. 2, no. 3, p. 160, 2021.
- [41] R. L. Chang and T. Pavlidis, “Fuzzy decision tree algorithms,” *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 7, no. 1, pp. 28–35, 1977.
- [42] A. A. Akinyelu, “Advances in spam detection for email spam, web spam, social network spam, and review spam : MI-based and nature-inspired-based techniques,” *Journal of Computer Security*, vol. 29, no. 5, pp. 473–529, 2021.
- [43] D. Hean, K. Bowyer, D. Kopans, P. K. Jr, R. Moore, K. Chang, and S. Munishkumar, “Automated detection of abnormal tissue in mammograms,” *Journal of Physics : Conference Series*, vol. 1994, no. 1, p. 012016, 2021.
- [44] C. P. Group, “MI summer school-day 5,” 2023.
- [45] D. W. Hosmer, S. Lemeshow, and R. X. Sturdivant, *Applied Logistic Regression*, 2013.
- [46] Y. Freund and R. E. Schapire, “A decision-theoretic generalization of on-line learning and an application to boosting,” *Journal of Computer and System Sciences*, vol. 55, no. 1, pp. 119–139, 1997.
- [47] T. Chen and C. Guestrin, “Xgboost : A scalable tree boosting system,” in *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 2016, pp. 785–794.
- [48] W. Samek, G. Montavon, S. Lapuschkin, C. J. Anders, and K.-R. Müller, “Explaining deep neural networks and beyond : A review of methods and applications,” *Proceedings of the IEEE*, vol. 109, no. 3, pp. 247–278, 2021.
- [49] M. A. Nielsen, *Neural Networks and Deep Learning*. San Francisco, CA, USA : Determination Press, 2015.
- [50] S. Min, B. Lee, and S. Yoon, “Deep learning in bioinformatics,” *Briefings in Bioinformatics*, vol. 18, no. 5, pp. 851–869, 2017.
- [51] Y. LeCun, Y. Bengio, and G. Hinton, “Deep learning,” *Nature*, vol. 521, no. 7553, pp. 436–444, 2015.

- [52] J. Patterson and A. Gibson, *Deep Learning : A Practitioner’s Approach*. O’Reilly Media, Inc., 2017.
- [53] S. Pouyanfar, S. Sadiq, Y. Yan, H. Tian, Y. Tao, M. P. Reyes, M.-L. Shyu, S.-C. Chen, and S. S. Iyengar, “A survey on deep learning : Algorithms, techniques, and applications,” *ACM Computing Surveys (CSUR)*, vol. 51, no. 5, pp. 1–36, 2018.
- [54] R. Manne and S. C. Kantheti, “Application of artificial intelligence in healthcare : chances and challenges,” *Current Journal of Applied Science and Technology*, vol. 40, no. 6, pp. 78–89, 2021.
- [55] H. Zhang, K. Tehlan, S. Ille, M. Schwendner, Z. Gong, A. Schroeder, B. Meyer, and S. M. Krieg, “Interhemispheric connections in the maintenance of language performance and prognosis prediction : fully connected layer-based deep learning model analysis,” *Neurosurgical Focus*, vol. 54, no. 6, p. E6, 2023.
- [56] D. Sun, J. Wulff, E. B. Sudderth, H. Pfister, and M. J. Black, “A fully-connected layered model of foreground and background flow,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2013, pp. 2451–2458.
- [57] B. Zhang, H. Li, X. Liang, X. Gu, and L. Zhang, “Fully connected layer-shared network architecture for massive mimo csi feedback,” *Electronics Letters*, vol. 58, no. 6, pp. 255–257, 2022.
- [58] S. Singh, M. Sharma, J. Heard, J. D. Lew, E. Saber, and P. P. Markopoulos, “Multimodal aerial view object classification with disjoint unimodal feature extraction and fully connected-layer fusion,” in *Big Data V : Learning, Analytics, And Applications*, vol. 12522. SPIE, 2023, p. 1252206.
- [59] A. G. Howard, M. Zhu, B. Chen, D. Kalenichenko, W. Wang, T. Weyand, and H. Adam, “Mobilenets : Efficient convolutional neural networks for mobile vision applications,” *arXiv preprint arXiv :1704.04861*, 2017.
- [60] A. G. Howard, M. Sandler, B. Chen, W. Wang, L. C. Chen, M. Tan, and H. Adam, “Searching for mobilenetv3,” in *Proceedings of the IEEE/CVF International Conference on Computer Vision*, 2019, pp. 1314–1324.
- [61] M. Tan and Q. V. Le, “Efficientnet : Rethinking model scaling for convolutional neural networks,” in *International Conference on Machine Learning*, 2019, pp. 6105–6114.
- [62] K. Simonyan and A. Zisserman, “Very deep convolutional networks for large-scale image recognition,” *arXiv preprint arXiv :1409.1556*, 2014.
- [63] K. He, X. Zhang, S. Ren, and J. Sun, “Deep residual learning for image recognition,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2016, pp. 770–778.
- [64] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, “Rethinking the inception architecture for computer vision,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2016, pp. 2818–2826.