



République Algérienne Démocratique et Populaire



Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

Université AMO de Bouira

Faculté des Sciences et des Sciences Appliquées

Département d'Informatique

Mémoire de Master

en Informatique

Spécialité : Ingénierie des Systèmes d'Information et Logiciel

Thème

Une approche IA pour la classification des tumeurs
cérébrales à partir des images IRM

Encadré par

— ALIOUAT WAHIBA.

Réalisées par

— BENANE Soumia.

— HAMBLI Lynda.

2020/2021

Remerciements

Nous tenons à remercier Dieu, le tout-puissant et miséricordieux, qui nous a donné la force, l'intelligence et la patience d'accomplir ce modeste travail.

Tout d'abord, ce travail ne serait pas aussi riche et n'aurait pas pu avoir le jour sans l'aide et l'encadrement de **Mm ALIOUAT Wahiba**, nous la remercions du fin fond de notre cœur pour la qualité de son encadrement exceptionnel, pour sa patience, sa rigueur et sa disponibilité durant notre préparation de ce mémoire. Nous n'oublierons jamais ses conseils.

Nous adressons nos remerciements au président et aux membres de jury d'avoir accepté le jugement de notre travail.

À tous nos enseignants du département informatique, un remerciement particulier et sincère pour tous les efforts fournis durant notre encadrement tout au long de ces cinq années, où nous avons acquis les connaissances nécessaires pour notre progression et amélioration durant le cursus qu'est le notre.

Nos remerciements à nos parents pour leurs aides, soutien moral et leurs encouragements tout au long de notre carrière universitaire.

Enfin, nous adressons nos plus sincères remerciements à tous nos proches et amis, qui nous ont toujours soutenues et encouragés au cours de la réalisation de ce mémoire.

Dédicaces

Je dédie ce travail À ma famille, mes parents, mes sœurs, mon frère, mon mari pour leurs amours, leurs présences permanentes leurs encouragements et leurs soutiens durant ces années d'études .

À mon fils qui a mis de la joie dans mon coeur .

Et aux professeurs, aux enseignants qui travaillent au sein du département informatique.

Et je remercie tous ceux qui nous ont aidés de proche et de loin.

BENANE Soumia.

Dédicaces

Je ne peux commencer sans évoquer le nom d'ALLAH notre Dieu le tout-puissant qui M'a donné la patience, la santé et son bien vaillance tout au long de ma vie, grâce à lui, j'ai pu réaliser ce travail, que je dédie :

À mes prunelles de mes yeux, mes chers parents **ALI** et **MESSAOUDI Ouardia** qu'ils ont rêvés de voir leur petite fille enfin diplômée, les mots ne sont pas assez pour vous remercier de tout ce que vous avez fait pour moi, sans vous, je ne serai jamais ce que je suis aujourd'hui.

À mon unique cher frère "**Redha**" et toute sa famille.

À mes chères sœurs qui m'ont offert tous leurs encouragements et leurs amours.

À mes chers petits neveux.

À ma grand-mère maternelle "**Rebiha**", cette pandémie t'as pris aussi tôt sans que tu pourras assister à ce jour, j'espère que tu seras fière de moi là où tu es, ta mort m'a tellement bouleversée, repose en paix chère grand-mère.

À ma cousine **Sabrinel**.

À ma team : **Sakina, Nada, Racha, Siham et Romaissa**, je n'oublierai jamais votre présence dans la mauvaise période que j'ai vécu dernièrement, je suis tellement reconnaissante d'avoir une team comme vous.

À **Soraya et Oussama** avec qui j'ai passé tous mes 5 ans universitaires.

À madame **Alliouat Wahiba** qui m'a considéré comme sa fille, je tiens à vous remercier madame pour tous vos conseils et votre compréhension.

À toute personne qui m'a encouragé de près ou de loin à réaliser ce travail.

HAMBLI Lynda.

Résumé

La tumeur cérébrale est l'une des maladies la plus dangereuse qui a causé le décès des enfants et les adultes, et cela, à cause de sa rapidité d'évolution qui peut nuire le fonctionnement de l'organisme.

À travers ce mémoire, nous allons proposer une solution(approche) basée sur le deep learning et le machine learning qui permet la classification des tumeurs cérébrales en quatre classes (sain, tumeur gliome, tumeur méningiome et adénome hypophysaire) en exploitant les images IRM fournies par les spécialistes.

Notre proposition est basée sur le concept transfert learning et utilise deux réseaux de neurones convolutifs pré-entraînés afin d'effectuer l'extraction des caractéristiques profondes des images de résonance magnétique du cerveau.

Les caractéristiques profondes extraites sont ensuite évaluées par le classificateur du machine learning SVM.

Les modèles créés ont prouvé leur efficacité en obtenant une meilleure accuracy durant le test.

Mots clés : Tumeur cérébrale, Deep Learning, Machine Learning, Tumeur gliome, Tumeur méningiome, Adénome hypophysaire, Classification, Transfert learning, Réseau de Neurones Convolutifs, SVM.

Abstract

Brain tumor is one of the most dangerous diseases that have caused the death of children and adults, because of its fast development which can affect the functioning of the body.

Through this thesis, we will propose a solution (approach) based on deep learning and machine learning which allows the classification of brain tumors into four classes (healthy, glioma tumor, meningioma tumor and pituitary) by using the MRI images provided. by specialists.

Our proposal is based on the transfer learning concept and uses two pre-trained convolutional neural networks to perform the extraction of deep features from magnetic resonance images of the brain.

The deep features extracted are then evaluated by the SVM machine learning classifier.

The models created have proved their efficiency by obtaining better accuracy during the test.

Keywords : Brain Tumor, Deep Learning, Machine Learning, Classification, Glioma tumor, Meningioma tumor, Pituitary, Transfer learning, Convolutional Neural Network, SVM.

ملخص

يعتبر ورم الدماغ من أخطر الأمراض التي تسببت في وفاة الأطفال والبالغين ، وذلك بسبب نموه السريع الذي يمكن أن يؤثر على عمل الجسم .
من خلال هذه المذكرة ، سنقترح حلاً (نهجاً) يعتمد على التعلم العميق والتعلم الآلي الذي يسمح بتصنيف أورام المخ إلى أربع فئات (صحية ، ورم دبقي ، ورم سحائي ، ورم نخامي) باستخدام صور التصوير بالرنين المغناطيسي المتوفرة. من قبل المتخصصين.
يعتمد اقتراحنا على مفهوم تعلم النقل ويستخدم شبكتين عصبيتين تلافيفيتين مدربتين مسبقاً لأداء استخراج الميزات العميقة من صور الرنين المغناطيسي للدماغ التي يتم تقييمها بواسطة مصنف التعلم الآلي.

الكلمات المفتاحية : ورم الدماغ ، التعلم العميق ، التعلم الآلي ، التصنيف ، ورم الدبقي ، ورم السحائي ، الغدة النخامية ، نقل التعلم ، الشبكة العصبية التلافيفية.

Table des matières

Table des matières	i
Table des figures	iv
Liste des tableaux	vi
Liste des abréviations	vii
Introduction générale	1
1 Contexte médical	3
1.1 Introduction	3
1.2 Notion de Base	3
1.2.1 Tumeur	3
1.2.2 Tumeur Primitive VS Tumeur Secondaire	5
1.3 Tumeur Cérébrale (TC)	6
1.3.1 Définition de la Tumeur Cérébrale (TC)	6
1.3.2 Symptômes de la Tumeur Cérébrale	6
1.3.3 Classification des Tumeurs Cérébrales	6
1.4 Imagerie Médicale	7
1.4.1 Définition d’Imagerie Médicale	7
1.4.2 Types d’Imagerie Médicale	8
1.4.3 Importance d’Imagerie Médicale	10
1.5 IRM et le Diagnostic des Tumeurs Cérébrales	11
1.5.1 Détection des Tumeurs Cérébrale à partir d’IRM	11

1.6	Conclusion	13
2	Deep Learning et Travaux Connexes	14
2.1	Intoduction	14
2.2	Machine Learning	14
2.2.1	Définition du Machine Learning	14
2.2.2	Types du Machine Learning	15
2.2.3	Les Algorithmes de Machine Learning	16
2.3	Deep Learning	18
2.3.1	Définition du Deep Learning	18
2.3.2	Fonctionnement du Deep Learning	18
2.3.3	Application du Deep Learning	19
2.3.4	Deep Learning VS Machine Learning	20
2.4	Les Algorithmes du Deep Learning	22
2.4.1	Réseaux de Neurones Convolutifs(CNN)	23
2.4.2	La Matrice De Confusion	27
2.5	Les travaux de recherche basés sur l'architecture CNN pour la classification des tumeurs cérébrales	29
2.5.1	Datasets des Images IRM Existants	29
2.5.2	Travaux Connexes	29
2.5.3	Comparaison entre les travaux	32
2.6	Conclusion	33
3	Approche et Solution Proposée	34
3.1	Introduction	34
3.2	Architecture Globale de Notre Proposition	34
3.2.1	Dataset	35
3.2.2	Visualisation de Données	37
3.2.3	Préparation de Données	37
3.2.4	Augmentation de Données	38
3.3	Entrainement de Nos Modèles	38
3.3.1	Fonction de Perte et d'optimisation	38
3.3.2	Le Classificateur Softmax	39

3.3.3	Classificateur SVM	39
3.3.4	Early Stopping	39
3.3.5	ReduceLROnPlateau	39
3.3.6	Checkpoint	40
3.3.7	Création des Modèles	40
3.4	Conclusion	43
4	Résultat et Discussion	44
4.1	Introduction	44
4.2	Environnement de Programmation	44
4.2.1	Plateforme (Environnement) De Programmation	44
4.2.2	Language De Programmation	45
4.3	Bibliothèques Utilisées	45
4.3.1	TensorFlow	45
4.3.2	Keras	46
4.3.3	Matplotlib	46
4.3.4	Sklearn	46
4.4	Résultats Obtenus	46
4.4.1	Phase d'Entraînement	46
4.4.2	Résultats Obtenus Durant le Test	50
4.5	Analyse et Discussion	50
4.5.1	Comparaison entre les Modèles Proposés	50
4.5.2	Comparaison avec d'autres Travaux de la Littérature	51
4.6	Prédiction de Nos Modèles	55
4.7	Conclusion	56
	Conclusion générale et Perspectives	57
	Bibliographie	59

Table des figures

1.1	Les Types d’Imagerie Médicale	8
1.2	Les composants d’IRM [11]	9
1.3	Image IRM de tumeur gliome[15].	11
1.4	l’image IRM de tumeur méningiome [16].	12
1.5	Les images IRM des trois types de TC [17].	12
2.1	Types du ML.	15
2.2	Hyperplan Optimal Avec Une Marge Maximale [22].	17
2.3	Fonctionnement du Deep Learning [26]	19
2.4	Relation entre IA, ML et DL [28]	20
2.5	la différence de performance entre le DL et le ML en fonction de la quantité de données [29].	21
2.6	L’extraction de caractéristique par ML comparé au DL [30].	22
2.7	Les Algorithmes du DL	22
2.8	Architecture du CNN [32].	23
2.9	Filtrage de L’image [33]	24
2.10	Réduction de la taille d’Image [34].	25
3.1	L’architecture globale de la solution.	35
3.2	Exemples de chaque type de tumeurs à partir d’IRM	36
3.3	Visualisation des données	37
3.4	Modèle basé sur DenseNet et Softmax.	41
3.5	Modèle basé sur DenseNet et SVM.	41
3.6	Notre architecture basé sur le modèle Xception et le classificateur Softmax.	42

3.7	Notre architecture basé sur le modèle Xception et le classificateur SVM. . .	43
4.1	Graphes accuracy et Loss en utilisant le modèle DenseNet121 durant 30 epoches sur 4 classes	47
4.2	Graphes accuracy et Loss en utilisant le modèle xception durant 30 epoches sur 4 classes	48
4.3	Graphes accuracy et Loss en utilisant le modèle xception durant 30 epoches sur 3 classes	49
4.4	Graphes accuracy et Loss en utilisant le modèle DensNet121 durant 30 epoches sur 3 classes	49
4.5	Comparaison entre notre modèle Dense121+softmax et le modèle de tra- vaux de littérature Dense169+svm	53
4.6	Comparaison entre les modèles xception+softmax/svm et GAN	54
4.7	Prédiction du modèle DenseNet+Softmax pour une classification de 4 classes 55	
4.8	Prédiction du modèle xception+softmax/svm pour une classification de 3 classes	56

Liste des tableaux

1.1	Tableau récapitulatif tumeur bénignes/malignes [2].	5
2.1	Avantages et Inconvénients Du SVM [24]	18
2.2	Matrice de Confusion	27
2.3	Matrices d'évaluation[44]	28
3.1	Répartition des données de 3 classes	36
3.2	Représentation de données	37
4.1	Accuracy et loss d'entraînement de chaque modèle pour la classification 4 classes.	47
4.2	Accuracy et loss selon chaque modèle testé sur la datasets de 3 classes. . .	48
4.3	Résultats du test selon la detaset de 4 classes	50
4.4	Résultats du test selon la detaset de 3 classes	50
4.5	Modèle performant sur le dataset de 4 classes	51
4.6	Modèles performant sur la dataset de 3 classes	51
4.7	Comparaison entre notre modèle proposé (DenseNet121+SVM) et un travail de littérature.	52
4.8	Comparaison entre notre modèle proposé(Xception+Softmaw/SVM)et un travail de littérature	54

Liste des abréviations

IA :	Intelligence Artificielle
ML :	Machine Learning
DL :	Deep Learning
TC :	Tumeur Cérébrale.
IRM :	Imagerie par Résonance Magnétique.
CNN :	Convolutional Neural Network.
FC :	Fully Connected.
SVM :	Support Vector Machine.
TL :	Transfer Learning.
2D :	2 Dimension.
3D :	3 Dimension.
Adam :	Adaptive Moment Estimation
CPU :	Central Processing Unit.
GPU :	Graphical Processing Unit.
TPU :	Tensor Processing Unit.
API :	Application Programming Interface.

Introduction générale

Parmi les pathologies du siècle les plus dangereuses et qui se développent d'une façon rapide et agressive, il existe le cancer. Ce dernier est dû aux transformations des cellules saines en cellules anormales. Cette transformation se déroule dans une brève période et peut attaquer n'importe quel organe et notamment le cerveau.

Le cancer cérébral ou la tumeur cérébrale se situe à l'intérieur du cerveau et peut se propager d'une façon incontrôlable. De plus, elle peut prendre différentes formes : les plus connues sont les gliomes, les méningiomes et les hypophysaires. Qu'elle soit bénigne ou maligne, la pathologie peut attaquer les deux sexes, les enfants ainsi que les adultes. C'est une maladie qui est moins fréquente, mais elle demeure la plus mortelle.

De nombreux outils d'imageries médicales permettent de traiter cette maladie. Néanmoins, l'imagerie par résonance magnétique (IRM) est la plus prometteuse et la plus conseillée dans le domaine médicale puisqu'elle permet de bien visualiser la tumeur, sa taille ainsi que son type.

En outre, le domaine médical est un domaine très sensible et complexe et la moindre erreur ou la moindre seconde perdue peut entraîner la perte du patient, c'est pourquoi ce domaine a besoin de ce qu'on appelle l'intelligence artificielle (IA). Cette dernière a révolutionné tous les secteurs.

L'IA a ouvert ses portes aux nombreux chercheurs pour développer des systèmes robustes qui vont permettre aux médecins de faciliter et accélérer la découverte de tumeurs en se basant sur le deep learning, en particulier les réseaux de neurones convolutifs (CNN).

Ainsi, cette technologie ne va pas complètement remplacer l'humain, mais va plutôt aider les médecins ainsi que les radiologues à faire le diagnostic nécessaire selon le taux de progression tumorale.

À travers ce mémoire, nous allons proposer une solution(approche) qui permet la classification des tumeurs cérébrales en quatre classes(sain, tumeur méningiome, tumeur gliome et Adénome hypophysaire) en exploitant les images IRM fournies par les spécialistes.

L'objectif de notre mémoire est d'améliorer la performance et l'accuracy, et cela, pour permettre une classification efficace des tumeurs cérébrales en utilisant le deep learning et le machine learning.

Le travail que nous avons mené s'articule autour de quatre chapitres :

Le premier chapitre : est consacré au contexte médical, il présente une vue sur la tumeur cérébrale, il définit ces trois différents types ainsi que l'imagerie par résonance magnétique, en particulier l'IRM.

Le deuxième chapitre : présente les différents concepts de Machine Learning et le Deep Learning et il détaille le Réseau de Neurones Convolutifs afin de nous permettre de réaliser un modèle .

Le troisième chapitre : représente notre proposition (solution) qui a été expliquée en passant par des étapes essentielles afin d'arriver à son implémentation finale.

Le quatrième chapitre : présente la discussion de résultats obtenus à partir de notre solution proposée.

Nous clôturerons ce mémoire par une conclusion générale qui résume le travail effectué.

Contexte médical

1.1 Introduction

Le corps humain est constitué de plusieurs différentes organes liés entre eux d'une façon spécifique, le fonctionnement de ces derniers est contrôlé par le cerveau.

Cet organe gère toutes nos activités, grâce à sa structure complexe et précise, il peut recevoir et émettre des messages ce qui permet une communication entre le monde extérieur et intérieur.

De nombreuses pathologies peuvent se développer à l'intérieur du cerveau ce qui peut influencer négativement sur le fonctionnement de tous ces organes et la tumeur cérébrale est l'une parmi ces pathologies. Cependant, l'imagerie par résonance magnétique est la technique d'imagerie médicale qui permet de détecter la localisation, le type ainsi que le volume de cette tumeur.

Dans ce chapitre, nous allons définir les notions de base sur les tumeurs, par la suite, nous allons présenter en détaille la tumeur cérébrale, ses types et l'imagerie par résonance magnétique qui est utilisée pour la diagnostiquer.

1.2 Notion de Base

1.2.1 Tumeur

Le terme « tumeur » fait référence à toute augmentation locale ou déformation volumique d'un organe [1].

Cependant, le développement et la croissance d'un tissu ou d'un organe sont conditionnés par des processus complexes permettant la régulation des différentes étapes de la vie d'une cellule : la prolifération, la différenciation, la sénescence et la mort cellulaire programmée. Tous ces phénomènes sont aussi mis en jeu lors du renouvellement des cellules dont la durée de vie est limitée. Au sein d'un tissu, l'équilibre entre ces processus est à l'origine de l'homéostasie tissulaire. Les anomalies de cette homéostasie, par augmentation de la prolifération et/ou diminution de la mort cellulaire, sont à l'origine de l'accumulation des cellules aboutissant à la formation d'une tumeur macroscopiquement visible [1].

1.2.1.1 Types de Tumeurs

Les tumeurs ne sont pas nécessairement des tumeurs cancéreuses, elles peuvent être existé en trois catégories : On constate que les tumeurs non-cancéreuses sont appelées tumeurs bénignes, et des tumeurs cancéreuses sont appelées tumeurs malignes. Et enfin, les tumeurs intermédiaires sont dites « atypiques » ou « évolutives », ces tumeurs sont initialement bénignes et peuvent se développer en cancer dans un laps de temps variable [2].

- 1. Tumeurs Bénignes :** sont des tumeurs non-cancéreuses et constituées des cellules qui se croissent lentement et restent localisées et confinées au tissu dont elles sont issues, elles peuvent atteindre un volume et un poids importants, et qui à l'analyse microscopique sont bien limitées et nettement séparées des tissus avoisinants, ces cellules ont une morphologie normale et ne présentent aucun caractère de malignité, Or si cette tumeur n'est pas complètement enlevée, elle peut se récidiver [2].
- 2. Tumeurs Malignes :** Contrairement aux tumeurs bénignes, elles sont classées comme cancéreuses [2]. Elles sont constituées de cellules qui ont une croissance rapide, elles provoquent une prolifération tumorale qui se propageant à distance et se développent en tumeurs secondaires dans d'autres organes ce qu'on appelle «métastase», à l'analyse microscopique ces tumeurs sont mal limitées et non encapsulées [2].

Après une éradication locale ce type de tumeur a tendance réapparaître, et l'évolution

en dehors des traitements se fait spontanément vers la mort [2].

La différence entre ces deux types de tumeur est résumée dans le tableau 1.1 suivant :

Tumeur Bénigne	Tumeur Maligne
Bien limitée	Mal limitée
Encapsulée	Non encapsulée
Histologiquement semblable au tissu d'origine	Plus ou moins semblable au tissu d'origine
Cellules régulières	Cellules irrégulières (cellules cancéreuses)
Croissance lente	Croissance rapide
Pas de métastase	Métastase

TABLE 1.1 – Tableau récapitulatif tumeur bénignes/malignes [2].

On peut distinguer de nombreuses typologies des tumeurs selon :

- Le type histologique.
- Les caractères maligne ou bénigne.
- le type tissulaire et selon l'organe : Le cancer du sein, du côlon, de pancréas, du prostate ainsi du cerveau

1.2.2 Tumeur Primitive VS Tumeur Secondaire

La Tumeur Primitive : est le développement de cellules cancéreuses dans un tissu de l'organisme, sans lien avec une pathologie cancéreuse antérieure, autrement dit : lorsque un organe est attaqué la première fois par une tumeur et les cellules subissent leur premier changement et déformation [3].

La Tumeur Secondaire ou Métastase : a pour origine une tumeur primitive préexistant, c'est-à-dire qu'il se propage à partir d'une tumeur primitive vers d'autres parties du corps et cela à travers la circulation sanguine [3].

1.3 Tumeur Cérébrale (TC)

1.3.1 Définition de la Tumeur Cérébrale (TC)

la tumeur cérébrale désigne toutes les tumeurs qui se situent à l'intérieur du crâne et qui peuvent se développer dans n'importe quelle zone du cerveau. Autrement dit, elles sont des tumeurs qui naissent à l'intérieur du cerveau. Cependant cette tumeur demeure la plus mortelle à cause de sa nature agressive et ses caractéristiques hétérogènes[4].

1.3.2 Symptômes de la Tumeur Cérébrale

Les Symptômes d'une TC se différencient selon le volume, la vitesse de propagation et la localisation de tumeur. les Symptômes les plus fréquents sont [4] :

- **Des maux de tête** : qui sont liés à une augmentation de la pression à l'intérieur du crâne.
- **Des troubles fonctionnels** : qui sont directement liés à la localisation de la tumeur et aux fonctions gérées dans cette zone du cerveau.
- **Des crises d'épilepsie**

1.3.3 Classification des Tumeurs Cérébrales

Qu'elle soit la tumeur primitive, secondaire, bénigne ou maligne, il existe des dizaines de TC différentes, par ailleurs les médecins classent la tumeur en fonction de trois facteurs [5] :

- Sa localisation dans le cerveau.
- Son degré d'agressivité.
- Son type.

Parmi les TC primitives les plus fréquents on trouve :

1.3.3.1 Les gliomes

Le terme de gliome regroupe l'ensemble des tumeurs issues des cellules gliales et représente le taux de tumeur cérébrale le plus élevé (50 %) [6].

Selon la classification de l'Organisation Mondiale de Santé, il existe trois types de gliomes

dont certains peuvent être bénins et d'autres maligne, selon son grade, on trouve :L'astrocytome, L'oligodendrogliome et L'oligoastrocytome ou gliome mixte[6].

1.3.3.2 Les méningiomes

Le cerveau est recouvert d'une fine toile Protectrice, c'est la méninge. Les méningiomes sont des tumeurs bénignes, d'évolution lente et qui sont issues des cellules méningées, ce type représente de 15 à 20% des tumeurs cérébrales [7].

Sous l'analyse microscopique, les méningiomes ont les caractéristiques suivantes :

- Grossièrement sphérique.
- Homogène.
- Volume variable.
- Rarement kystique.

1.3.3.3 L'adénomes hypophysaire

L'hypophyse appartient au diencephale, elle est située dans la selle turcique et reliée par la tige pituitaire à l'hypothalamus. Elle est constituée de deux parties, l'antéhypophyse et la posthypophyse [8].

L'adénome hypophysaire est une tumeur bénigne développée aux dépens de l'antéhypophyse. Cette tumeur représente un taux de 8 à 10 % des tumeurs intra crâniens. En fonction de sa taille, on décrit quatre types : les picoadénomes, les microadénomes, les macroadénomes et les adénomes géants [8].

1.4 Imagerie Médicale

1.4.1 Définition d'Imagerie Médicale

L'imagerie médicale est une discipline médicale mettant en œuvre les moyens actuels pour observer la structure interne du corps humain, le fonctionnement des organes ainsi que le développement interne des maladies en utilisant des sources de rayonnement (pas nécessairement ionisant) [9].

1.4.2 Types d'Imagerie Médicale

Le développement de la technologie a permis l'apparition de différentes techniques qui sont utilisées dans la production d'imagerie médicale, cependant les images fournissent par ces techniques doivent être codées selon le type choisit.

Ces différentes modalités sont mentionnées sur la figure 1.1 suivante :

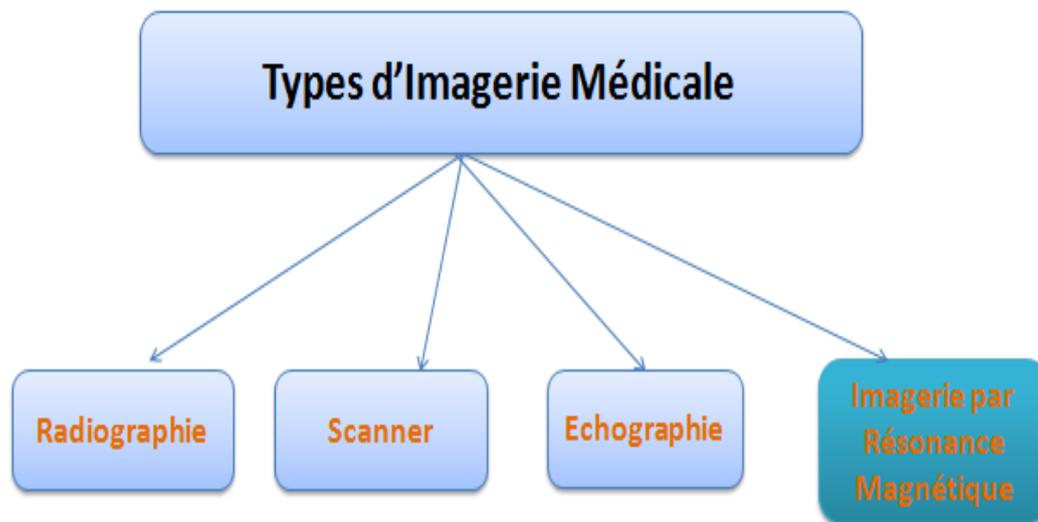


FIGURE 1.1 – Les Types d'Imagerie Médicale

Notre thème est basé sur les images par résonances magnétiques (IRM), dans ce qui suit, nous allons détailler cette modalité.

1.4.2.1 Imagerie par Résonance Magnétique (IRM)

L'imagerie par résonance magnétique est une technique d'examen qui permet de créer des images d'une partie du corps ou des organes à l'aide d'un appareil d'imagerie médicale cylindrique. Cet appareil est constitué de cinq composants sur lesquels s'appuie son fonctionnement et la figure 1.2 ci-dessous montre les principaux de ces composants [10].

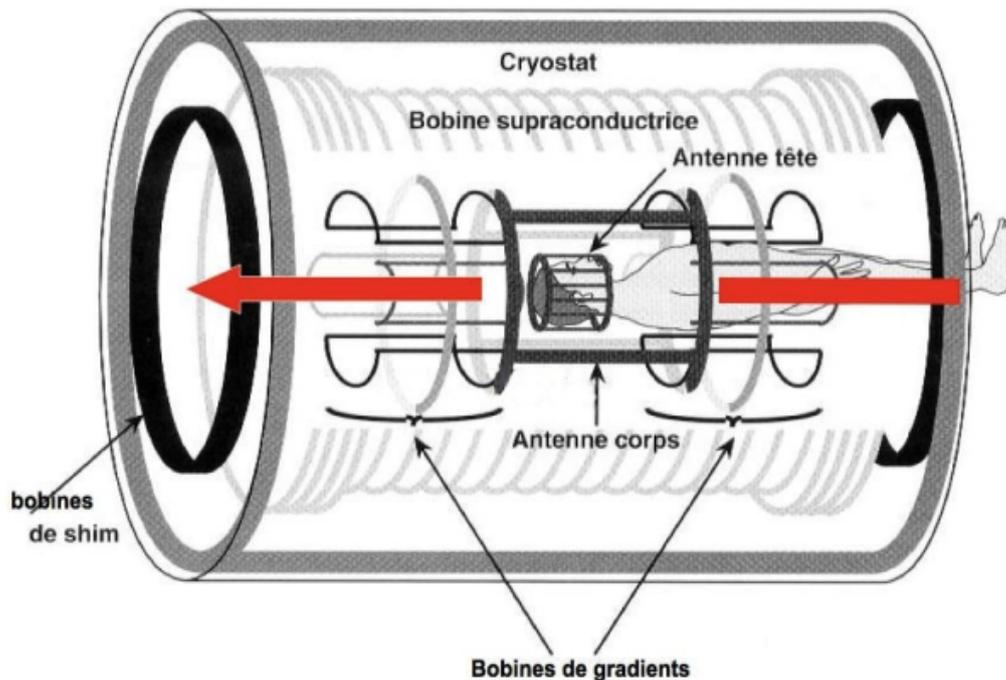


FIGURE 1.2 – Les composants d'IRM [11]

Elle utilise un aimant très puissant (d'où le terme de magnétique) qui fait réagir un composant de notre corps qu'on appelle l'hydrogène. L'hydrogène est présent dans les molécules d'eau du corps humain [10].

Une IRM permet ainsi de réaliser une succession de photographies de l'intérieur du corps (plusieurs dizaines d'images). Les images sont visualisées sur un écran d'ordinateur sous forme de coupes. L'ordinateur permet de reconstruire les images pour étudier par exemple uniquement les vaisseaux sanguins (on parle alors d'angio-IRM) [10].

L'examen est réalisé par un manipulateur de radiologie sous la responsabilité d'un médecin radiologue qui analyse les images.

Une IRM permet dans certains cas de rechercher des anomalies que l'on repère moins bien avec d'autres techniques d'imagerie médicale. Elle permet une meilleure localisation des organes, de détecter des tumeurs ainsi qu'une infection ou une hémorragie. Elle permet ainsi d'obtenir une vue **2D** et **3D** [10] [7].

Cette technique a aussi ses limites et certains organes ou certaines parties du corps sont moins visibles par cet examen :

Par exemple : une IRM est particulièrement performante pour explorer le cerveau, mais

pas les poumons. D'autres examens peuvent alors être proposés [10].

1.4.2.2 Principe de Fonctionnement

Lors d'un examen IRM, le patient est introduit dans un anneau capable de générer des champs magnétiques. D'abord, un champ est généré, pour aligner tous les moments magnétiques des atomes d'hydrogène dans la même direction, l'axe z autour duquel ils tournent [12].

Ensuite, plusieurs impulsions les radiofréquences sont générées. Les moments des atomes d'hydrogène vont donc être déplacés par ces impulsions avant de revenir, tout en continuant de tourner, dans leur direction initiale, l'axe z. Ce phénomène est appelée relaxation [12].

L'appareil d'IRM mesure le retour des moments magnétiques dans deux directions. La première suit l'axe longitudinal ou axe z, donnant une image appelée **T1**. La composante transversale, soit perpendiculaire à l'axe z est mesurée pour former l'image **T2**. Chaque tissu a une concentration et organisation en hydrogène caractéristique, les images IRM **T1** et **T2** permettent donc de différencier les tissus [12].

1.4.3 Importance d'Imagerie Médicale

L'imagerie médicale a révolutionné le domaine médical en apportant de grands changements à l'industrie des soins de santé. Elle a bouleversé le monde scientifique en le fournissant de l'informations nécessaires sur l'anatomie humaine, ce qui lui a permis de faire ses preuves [13].

Cette technologie permet de planifier l'exécution d'une opération chirurgicale en mettant la lumière sur les risques possibles et simplifiant la démarche à adapter par la compréhension exacte du schéma du corps humain et de l'endroit visé par l'opération (possibilité de malformations congénitales facilement réparable en plan 3D) [13].

L'imagerie médicale permet de diagnostiquer les tumeurs, suivre leurs évolutions et définir soigneusement leurs types en utilisant la modalité IRM [7].

1.5 IRM et le Diagnostic des Tumeurs Cérébrales

Lorsqu'une tumeur est détectée, l'IRM peut permettre de mieux se rendre compte de ses caractéristiques, autrement dit, elle permet de situer la tumeur, de mesurer sa taille ainsi que de déterminer le type de la tumeur et de contrôler l'efficacité de certains traitements. et cela en utilisant le temps de relaxation T1 et T2, la valeur prise par T2 dépend de milieu étudié, plus ce dernier est fluide plus les valeurs prises sont grandes, Dans le cas des tissus cérébraux. T2 à tendance à être inférieur à T1 [14].

1.5.1 Détection des Tumeurs Cérébrale à partir d'IRM

L'IRM permet une visibilité clair des constituants internes de la tumeur et notamment les particules kystiques, qui apparaissent dans la signalisation en T1 hyposignal et hyper signal en T2, suivie d'une calcification peu ou pas visible [7].

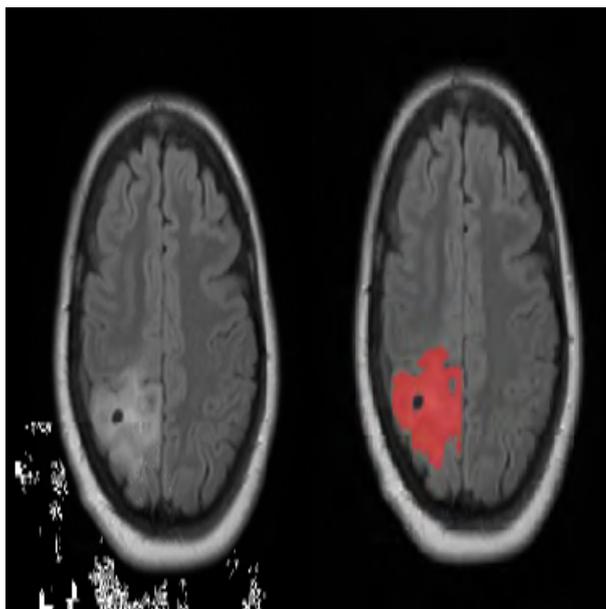


FIGURE 1.3 – Image IRM de tumeur gliome[15].

En IRM T1, la tumeur apparaît en isosignal qui peut facilement passer inaperçue surtout si la lésion et l'œdème associés sont de petite taille. En T2 est isointense en l'absence de calcification et hypointense dans le cas contraire [7].

la figure 1.4 représente un exemple d'une tumeur méningiome.

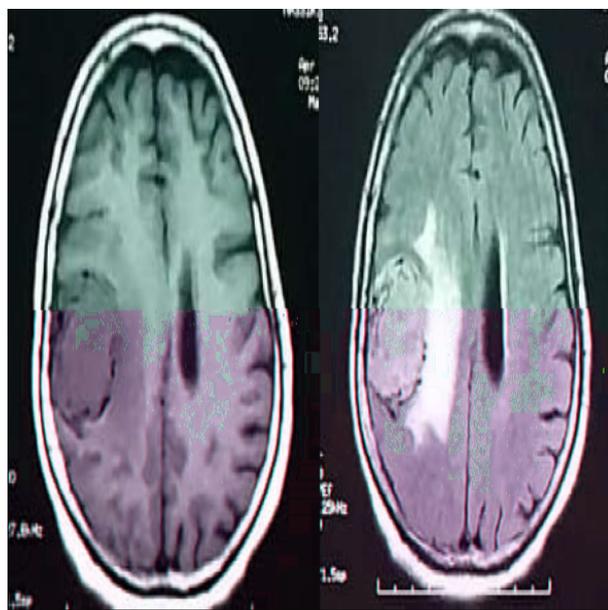


FIGURE 1.4 – l'image IRM de tumeur méningiome [16].

La figure 1.5 représente les deux types de tumeurs qu'on vient de les expliquer précédemment ainsi que l'adénome hypophysaire :

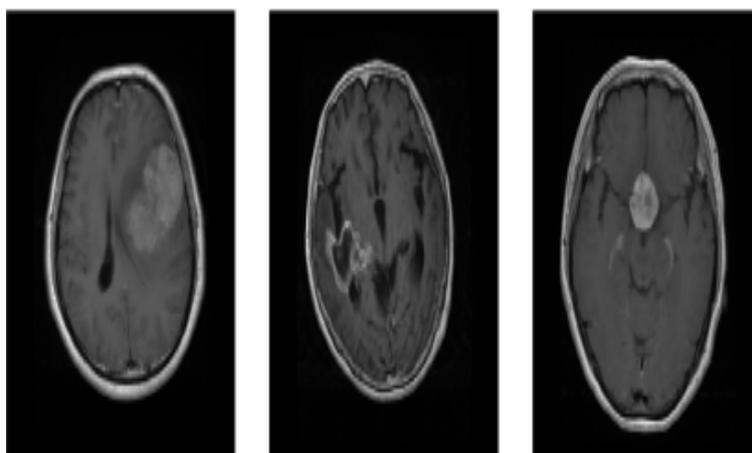


FIGURE 1.5 – Les images IRM des trois types de TC [17].

1.6 Conclusion

Dans ce chapitre, nous avons abordé de manière générale les différentes notions de bases relatives à la tumeur, puis nous avons présenté la tumeur cérébrale et ses types les plus fréquents.

Ensuite, nous avons présenté les types d'imagerie médicale et une vue détaillée sur l'imagerie par résonance magnétique.

Au final, nous avons montré le diagnostic des tumeur cérébrale à partir d'imagerie par résonance magnétique.

Dans le chapitre suivant, nous allons aborder le Machine Learning et le Deep Learning ainsi que le Réseau de Neurones Convolutifs.

Deep Learning et Travaux Connexes

2.1 Introduction

L'arrivée de l'intelligence artificielle « IA » a simplifié divers domaines dans notre vie quotidienne et notamment le domaine médical, le deep learning qui est une partie de L'IA est la meilleure solution pour traiter et classifier une quantité de données massive et cela est due aux modèles qu'il offre.

Dans le cadre de ce chapitre, nous allons présenter les deux domaine de l'intelligence artificielle, tout d'abord nous allons parlé sur le machine learning et ses types d'apprentissages, puis sur le deep learning, son fonctionnement.

Ensuite, nous allons déterminer la différence entre les deux domaines et nous allons présenter le Réseau de Neurones Convolutif ainsi que les différentes métriques d'évaluation.

Au final,nous allons parler sur les travaux connexes qui ont été utilisés pour la classification des tumeurs cérébrale à partir des images IRM.

2.2 Machine Learning

2.2.1 Définition du Machine Learning

Le Machine Learning, "l'apprentissage automatique" ou ML en bref, c'est un sous-domaine de l'IA qui est apparu depuis les années 1950, mais il n'a commencé à se développer qu'en 1990 [18].

ML signifie que les systèmes informatiques peuvent apprendre sans être programmé cela implique que ces systèmes ont la capacité de résoudre des problèmes simples et complexes en appliquant différents algorithmes et en exploitant les expériences passées afin de faire des prédictions réussies [19].

2.2.2 Types du Machine Learning

Afin de pouvoir résoudre différents problèmes cette technologie dispose de 4 types d'apprentissages, comme il est mentionné sur la figure 2.1 ci-dessous :

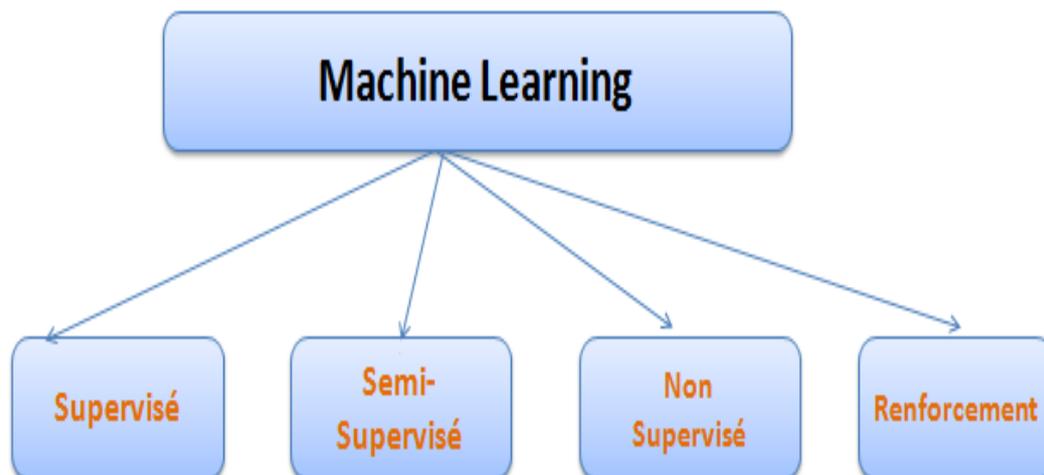


FIGURE 2.1 – Types du ML.

1. Apprentissage Supervisé : les données de ce type d'apprentissage se présentent comme une paire d'entrée et de sortie, son but est d'apprendre à prédire la valeur de sortie à partir des caractéristiques de celles de l'entrée, et selon la valeur prédite, il existe deux types de catégories [20] :

La classification : quand on dispose d'une valeur finie ou discrète, elle est fréquemment utilisée dans le diagnostic médicale [20].

La régression : quand on dispose d'une valeur continue(sous la forme d'un nombre)[20].

2. **Apprentissage Semi-Supervisé** : c'est un apprentissage qui se produit sur la base d'ensembles de données partiellement étiquetées [21].
3. **Apprentissage Non Supervisé** : Contrairement à l'apprentissage supervisé, ce type dispose seulement des caractéristiques des valeurs d'entrées comme l'ensemble des données d'apprentissage, et à la base de ses valeurs, il doit apprendre par lui-même pour enfin trouver la valeur de sortie [20].
4. **Apprentissage par Renforcement** : Un agent reçoit des informations sur son environnement et apprend à choisir des actions qui maximiseront une certaine récompense [20].

2.2.3 Les Algorithmes de Machine Learning

Le choix de l'algorithme qui permet d'atteindre des prédictions fidèles se fait selon le problème étudié, néanmoins, il existe de nombreux algorithmes de Machine Learning comme : Random Forest, Arbre de décision et Support Vecteur Machine (SVM).

Concentrons-nous par la suite sur l'algorithme SVM qui est énormément utilisé pour la classification des images.

2.2.3.1 Support Vecteur Machine (SVM)

Support Vector Machine ou SVM est l'un des algorithmes d'apprentissage supervisé qui est utilisé pour les problèmes de classification et de régression [22].

Son but consiste de créer la meilleure ligne ou frontière de décision qui puisse séparer l'espace à n dimensions en classes afin que nous puissions facilement placer le nouveau point de donnée dans la catégorie correcte à l'avenir. Cette meilleure frontière de décision est appelée un hyperplan [22].

Un hyperplan permet de maximiser la marge, autrement dit, il permet de déterminer la distance euclidienne minimale entre l'hyperplan et les points de données les plus proches de chaque classe, ces derniers sont appelés **vecteurs supports** [22].

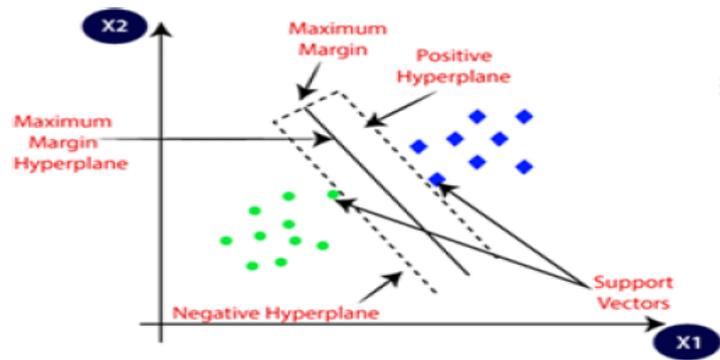


FIGURE 2.2 – Hyperplan Optimal Avec Une Marge Maximale [22].

2.2.3.2 Type du SVM

Il existe deux types du SVM [23] :

1.SVM linéaire : est exploité pour les données qu'on peut séparer de façon linéaire ; dans le cas où un ensemble de données serait divisé en deux catégories, mais en employant une ligne droite unique, on dira que c'est des données linéairement séparables, et le classificateur exploité pour effectuer cette tâche, classificateur linéaire SVM.

2.SVM Non-linéaire : est exploité pour les données séparées non linéairement comme son nom l'indique. Cela veut dire : si on ne peut pas utiliser une ligne droite pour diviser un ensemble de données, donc ces dernières sont dites données non-linéaires et le classificateur exploité pour effectuer cette tâche, classificateur SVM non linéaire.

2.2.3.3 Avantages et Inconvénients du SVM [24]

Support Vecteur Machine	
Avantages	Inconvénients
Capacité à traiter de grandes dimensionnalités (variables élevées)	Problème lorsque les classes sont bruitées (multiplication des points supports)
Non paramétrique	Pas de modèle explicite pour les noyaux non linéaires (utilisation des points supports)
Traitement des problèmes non linéaires avec le choix des noyaux	Difficulté d'interprétations (ex. pertinence des variables)

TABLE 2.1 – Avantages et Inconvénients Du SVM [24]

2.3 Deep Learning

2.3.1 Définition du Deep Learning

Deep learning ou l'apprentissage profond en français appelé également l'apprentissage hiérarchique est un sous-domaine le plus avancé dans l'IA, qui se base sur les algorithmes inspirés par le fonctionnement du cerveau humain pour atteindre des connaissances [16], cette technologie n'a connu un épanouissement important que depuis les années 2010 [18].

2.3.2 Fonctionnement du Deep Learning

Le principe de fonctionnement du deep learning repose sur les réseaux de neurones artificiels, ces neurones sont regroupés en trois types de couches différents et chaque connexion entre ces neurones est associée à un poids [25] :

- 1. Une couche d'entrée :** Elle est constituée de l'ensemble des variables d'entrée.
- 2. Une couche de sortie :** Elle est constituée de l'ensemble des neurones de sortie du réseau, c'est cette couche-là qui fournit les sorties principales.
- 3. Une ou plusieurs couches cachées :** Ce sont les couches qui se trouvent entre la couche d'entrée et la couche de sortie. Elles définissent l'activité interne du réseau.

La figure 2.3 explique l'enchaînement de ces couches :

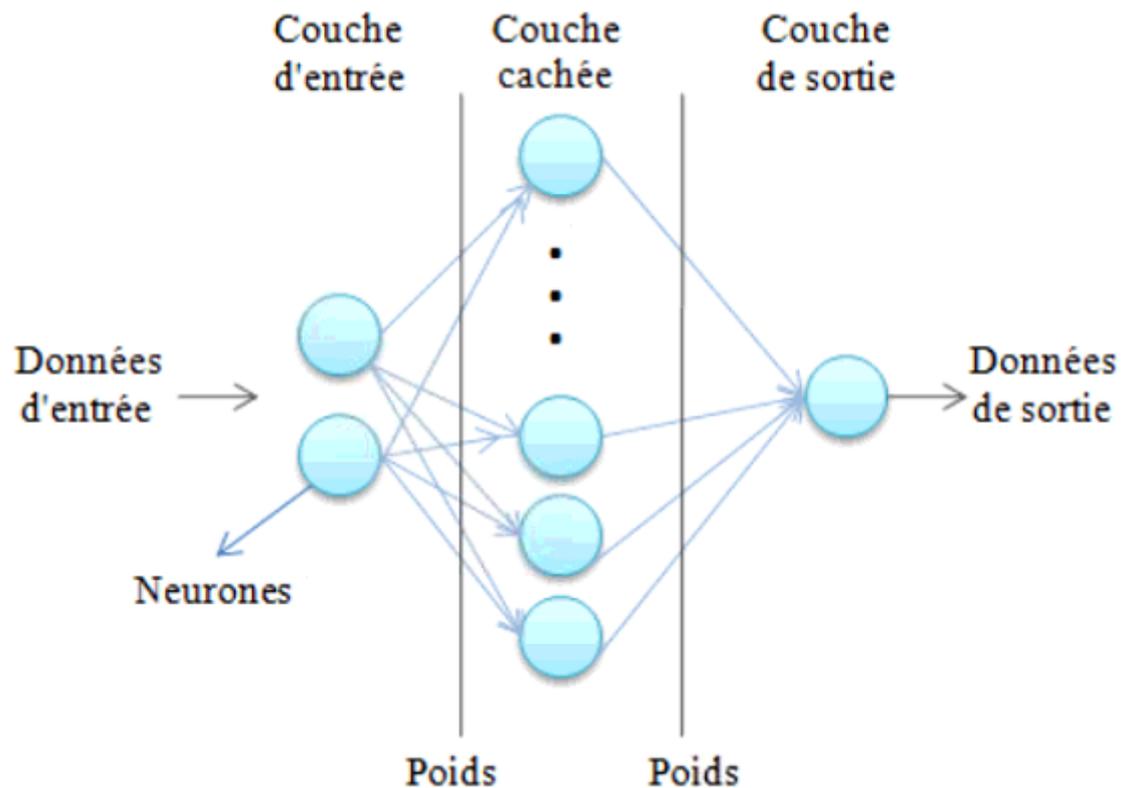


FIGURE 2.3 – Fonctionnement du Deep Learning [26]

L'entraînement du réseau de neurones consiste à déterminer des valeurs de poids W_{ij} qui permettent à la couche de sortie de classer précisément les images de l'ensemble d'entraînement. [25]

2.3.3 Application du Deep Learning

Le deep learning joue un rôle très important dans nos vies, cela a eu un impact énorme sur plusieurs secteurs, citons quelques-unes de ces applications [71] :

- **Cybersécurité** : consiste à protéger les systèmes informatiques contre les attaques inattendues, en utilisant les différentes techniques du DL.
- **Traduction Automatique** : c'est le passage d'un simple mot saisi à sa prononciation. Plus la langue est répandue et plus la traduction est efficace.

À noter que c'est en se servant du DL que la traduction automatique s'est améliorée.

- **Robot industriel** : Un robot permet aujourd'hui de réduire le nombre d'employés dans plusieurs entreprises mais il garantit aussi d'améliorer la quantité ainsi que la qualité industrielle, et cela grâce aux DL.
- **Conduite Automatique** : Les voitures sont devenues capables de détecter automatiquement les piétons, les feux rouges, et la circulation.
- **Médecine** : Le développement du DL a permis d'aller plus loin dans la médecine, cette technologie a facilité aux médecins de choisir le diagnostic nécessaire selon le cas de chaque patient, il est possible de faire la détection et la classification de plusieurs pathologies en temps réel, ce qui améliore la chance de guérison. Le deep learning est également utilisé pour examiner les images en 3D et d'autres procédés que l'humain ne peut faire sans cette technologie.

2.3.4 Deep Learning VS Machine Learning

La différence entre ces deux technologies est mentionnée par les points suivants [27] :

- Le Deep Learning est un sous domaine du Machine Learning qui est lui-même un sous domaine de l'IA comme c'est illustré sur la figure 2.4 ci-dessous :

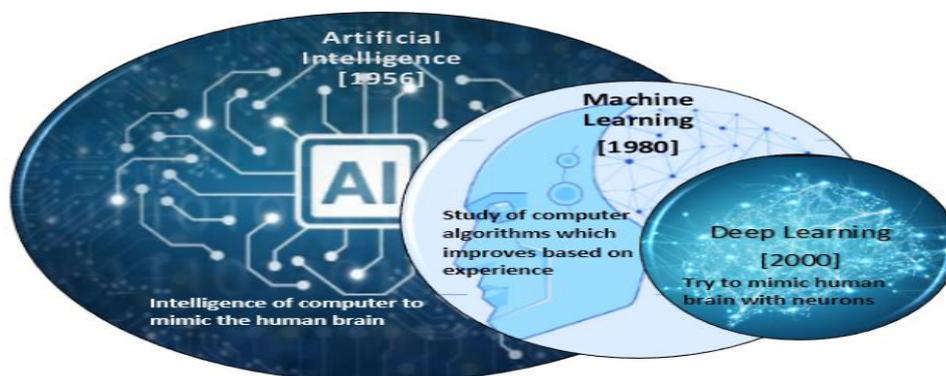


FIGURE 2.4 – Relation entre IA, ML et DL [28]

- La différence principale entre le ML et le DL c'est l'adaptation aux données : la figure 2.5 montre que les algorithmes de DL ne sont pas aussi performants lorsque les volumes de données sont faibles, car ces algorithmes ont besoin d'une grande quantité de données pour pouvoir les comprendre parfaitement, contrairement aux algorithmes de ML traditionnels qui ont un nombre limité de données qu'ils peuvent recevoir [27].

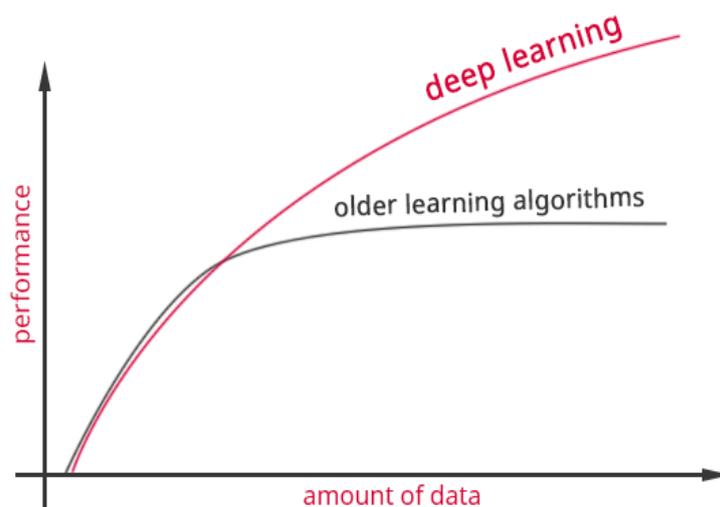


FIGURE 2.5 – la différence de performance entre le DL et le ML en fonction de la quantité de données [29].

- Pour optimiser les nombreuses opérations matricielles utilisées au DL, il est nécessaire d'utiliser des machines de haute performance pour lui permettre un meilleur fonctionnement, cependant le GPU est le plus utilisé au DL contrairement au ML [27].
- L'extraction des caractéristiques est une étape qui prend beaucoup de temps et nécessite une connaissance spécialisée. Cependant en ML, cette étape doit être déterminée par un expert puis codée selon la forme du type de données nécessaires, or en DL cette étape est faite automatiquement ce qui permet de réduire l'effort de conception d'un extracteur de caractéristique de chaque problème[27].

la figure 2.6 suivante montre l'extraction de caractéristique effectué en ML et DL.

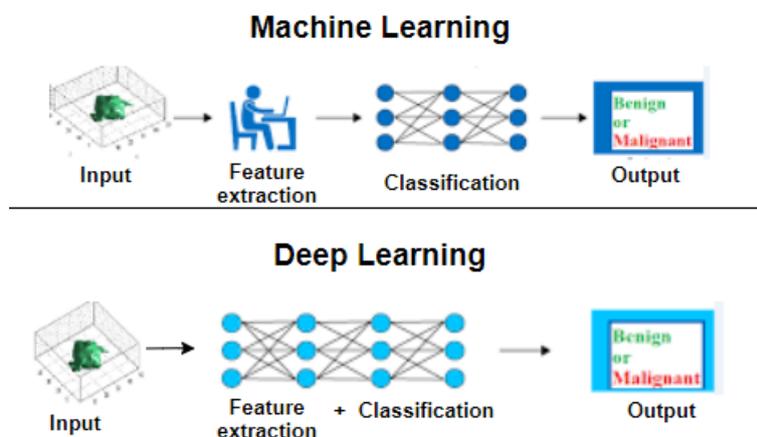


FIGURE 2.6 – L'extraction de caractéristique par ML comparé au DL [30].

2.4 Les Algorithmes du Deep Learning

Selon le type d'apprentissage, il existe plusieurs différents algorithmes du deep learning qui sont mentionnés sur la figure 2.7 suivante :

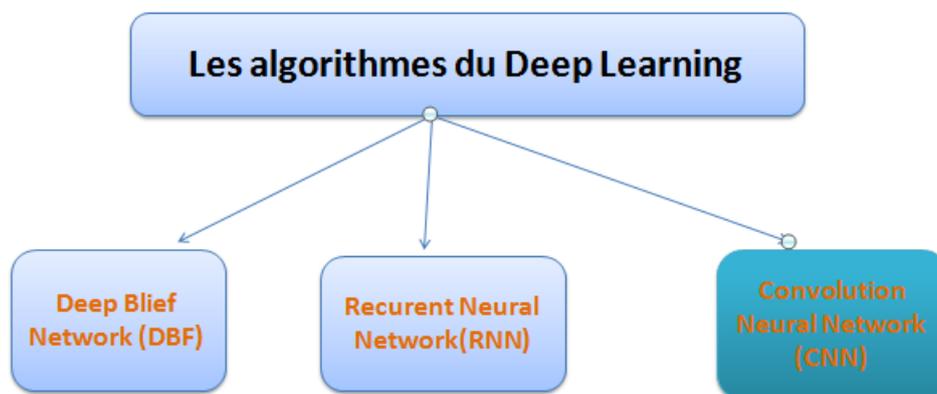


FIGURE 2.7 – Les Algorithmes du DL

Pour réaliser la classification des images médicales, le réseau convolutif (CNN) est fréquemment utilisé, dans ce qui suit, nous allons l'expliquer en détaille.

2.4.1 Réseaux de Neurones Convolutifs(CNN)

Le réseau de neurones convolutif "Neural Network" : est un modèle mathématique dont la conception est inspirée des neurones biologiques, il est efficacement utilisé pour la détection, la segmentation ainsi que la classification des images médicales [31].

Ce réseau contient plusieurs différentes couches qui permettent d'établir deux étapes importants [31] :

- **L'extraction des caractéristiques** : cette étape consiste à appliquer un certain nombre de filtres afin de réduire la résolution de chaque image, on obtiendra à la fin une nouvelle image appelée carte de convolution qui sera mise à plat et concaténée avec un vecteur de caractéristique. Cet étape peut se reproduire dans plusieurs reprises.
- **La classification** : se trouve à la fin de chaque réseau convolutif, consiste à exploiter le vecteur de caractéristique comme entrée et d'utiliser un classificateur bien déterminé qui permettra d'obtenir une sortie finale qui comportera les (i) classes de ces images.

La figure 2.8 suivante illustre ces deux étapes :

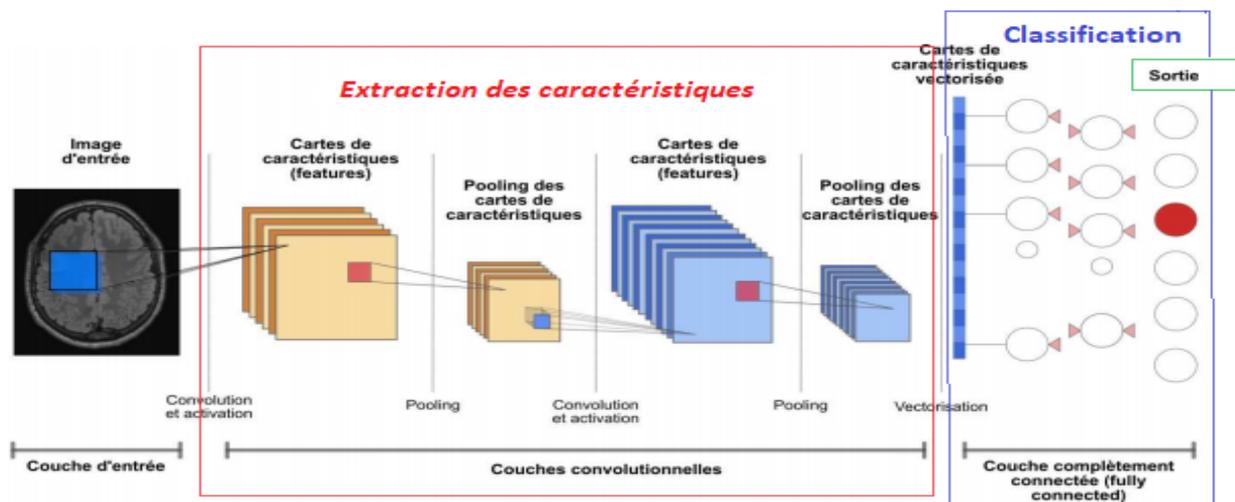


FIGURE 2.8 – Architecture du CNN [32].

2.4.1.1 Les Couches de Réseau de Neurones Convolutif

1. La Couche de Convolution "Convolution Layer"

Elle est composée d'un ensemble de filtres (Kernel), ces filtres fonctionnent en divisant l'image en petits morceaux pour permettre l'extraction de ces caractéristiques. Le filtre appliqué convole avec l'image en utilisant des poids spécifiques, ces poids seront multipliés par ces caractéristiques, ce processus continuera, et cela, en glissant le filtre sur toute l'image, au final, on obtiendra en sortie une matrice de pixel [31].

la figure 2.9 explique le fonctionnement de cette couche :

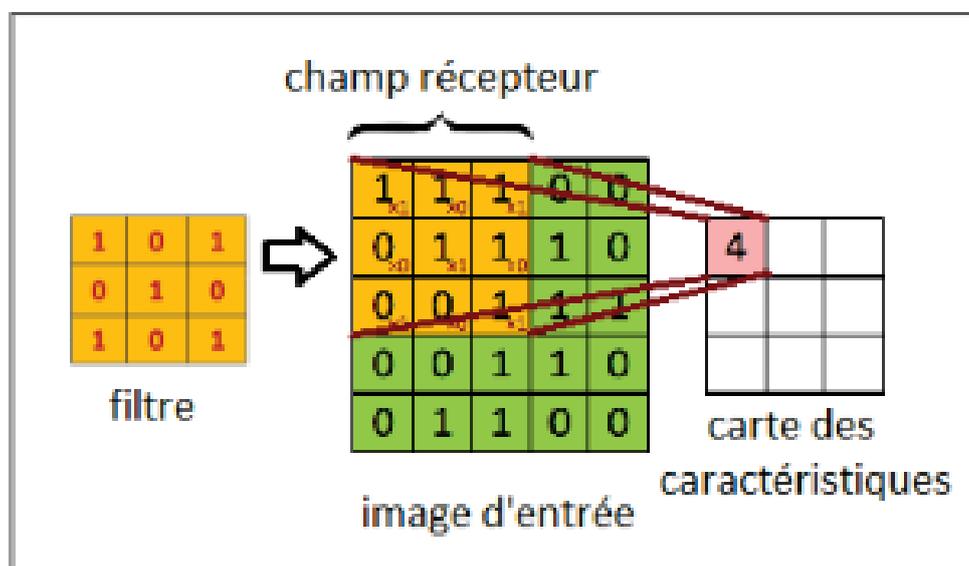


FIGURE 2.9 – Filtrage de L'image [33]

2. La Couche de Pooling

Le résultat de la couche précédente est l'entrée cette couche, elle capture les grandes images et réduit les paramètres pour préserver les informations importantes, elle préserve la valeur maximale, minimale ou la moyenne des valeurs [31].

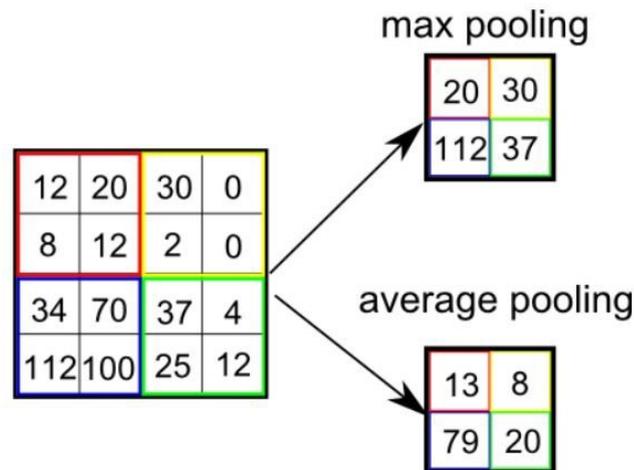


FIGURE 2.10 – Réduction de la taille d'Image [34].

3.La Couche Entièrement Connecté "Fully Connected Layer"

Cette couche est utilisée à la fin du réseau, en exploitant la sortie final de l'étape d'extraction, elle permet la classification des classes [31].

2.4.1.2 Les Architectures du CNN :

Différents efforts ont été déployés pour l'amélioration des performances des CNN, cela a contribué à avoir de nombreuses architectures, nous mentionnant quelques-unes :

- **VGG [35]** : cette architecture était inventé en 2014 par les deux chercheurs Simonyan et Zisserman de laboratoire Visuel Geometry Group de l'université d'Oxford, dans le but d'améliorer la classification des images dans la plus grande base données ImageNet, le VGG est basé sur l'architecture du CNN et il offre 6 différents réseaux convolutifs, les plus performants sont VGG16 et VGG19, la seule différence entre ces deux réseaux est le nombre de couches.
- **ResNet [36]** : est l'abréviation du Résiduel Network été proposé en 2015, il appartient aux modèles CNN, Le ResNets est constitué des blocs de convolution et d'identité, qui relie la sortie d'une couche à l'entrée d'une couche plus proche.
- **DenseNet [37]** : était proposé par Gao Huang, Zhuang Liu et Laurens van der Maaten, cette architecture permet de rendre la connexion entre les couches plus courte, autrement dit chaque sortie d'une couche sera l'entrée des couches suivantes. DenseNet a plusieurs version telles-que : Dense121, Dense169 et Dense201.

- **Xception [38]** : l'architecture **Xception** ou « Extreme Inception » était proposée par François Chollet le créateur du Keras, il est inspiré par l'architecture Inception, ils ont presque les mêmes paramètres, il contient 36 couches.

2.4.1.3 Problème d'Overfitting

2.4.1.3.1 Définition d'Overfitting : L'overfitting ou le sur-apprentissage en français se produit lorsque le modèle s'adapte bien à l'ensemble de données d'entraînement, ce qui implique que le modèle trouve des difficultés lors de la généralisation des nouveaux exemples. Cela conduira à une augmentation supérieure de la précision sur l'ensemble de formation (entraînement) par rapport à l'ensemble de tests [39].

2.4.1.3.2 Techniques pour Éviter l'Overfitting : Parmi les techniques qui sont couramment utilisées pour réduire l'overfitting sont :

1. **Validation croisée :** « cross validation » est une technique d'évaluation des modèles qui permet d'obtenir une estimation des performances du prédicteur, en utilisant toutes les données disponibles, ceci est obtenu en faisant plusieurs tests sur différents ensembles d'apprentissage et de test, et en faisant la moyenne des résultats[40]. Il existe plusieurs méthodes de la validation croisée comme : K-fold, leave one out et Repeated Random SubSampling [40].
2. **Transfer learning :** C'est une technique d'apprentissage par laquelle un modèle déjà Entraîner est utilisé pour apprendre un autre ensemble de données (S. Deepak, 2019). Cette Technique est plus adaptée lorsque l'ensemble de données est de faible quantité [41]. Il est utilisé selon trois stratégies :
 - **Extraction des caractéristiques "Feature Extractor" :** Cette stratégie consiste à utiliser un modèle pré-entraîner sur une grande quantité de données comme extracteur de caractéristiques, cela nécessite de retirer la dernière couche "fully connected layer" et de fixer tous les autres paramètres [42].
 - **Fine Tuning total :** Il s'agit de remplacer la couche fully connected layer par un classificateur adapté au problème [41].
 - **Fine tuning partiel :** Cette stratégie combine les deux stratégies précédentes[41].

2.4.2 La Matrice De Confusion

Est également appelée matrice d'erreur et est représentée par un tableau « voir Table 2.2 [43] » qui décrit les performances d'un modèle de classification sur un ensemble de données de test dans l'apprentissage automatique. Dans le tableau ci-dessus, la classe 1 est représentée comme le tableau positif et la classe 2 comme le tableau négatif.

Toute prédiction unique peut appartenir à l'un des quatre compartiments suivants [43] :

- * **Vrai positif (TP)** : le vrai label de l'instance donnée est positif, et le classificateur le prédit également comme positif [43] .
- * **Vrai négatif (TN)** : la vraie étiquette est négative et le classificateur prédit également un négatif [43] .
- * **Faux positif (FP)** : le vrai label est négatif, mais le classificateur le prédit à tort comme positif [43] .
- * **Faux négatif (FN)** : le vrai label est positif, mais le classificateur le prédit à tort comme négatif [43] .

Matrice de confusion		
	Class 1 Predicted	Class 2 Predicted
Class 1 Actual	TP	FN
Class 2 Actual	FP	TN

TABLE 2.2 – Matrice de Confusion

L'évaluation de notre modèle est une partie essentielle de notre projet. Notre modèle peut nous donner des résultats satisfaisants lorsqu'il est évalué à l'aide d'une métrique. Dans notre cas, nous avons utilisé l'Accuracy, Precision, Recall, et f1-score pour mesurer les performances de notre modèle proposé.

Métrique d'évaluation	Définition	Équation
Accuracy	Est la mesure de performance la plus intuitive et il s'agit simplement d'un rapport entre les observations correctement prédites et les observations totales	Accuracy = $\frac{TP+TN}{TP+FP+FN+TN}$
Precision	La précision est le rapport entre les observations positives correctement prédites et le total des observations positives prédites.	Precision = $\frac{TP}{TP+FP}$
Recall	Le Recall ou rappel en français est le rapport entre les observations positives correctement prédites et l'ensemble des observations de la classe réelle - oui.	Recall = $\frac{TP}{TP+FN}$
F1-score	Le score F1 est la moyenne pondérée de la précision et le rappel. Par conséquent, ce score prend en compte les faux positifs et les faux négatifs.	F1-score = $\frac{2*(Recall * Precision)}{Recall+Precision}$

TABLE 2.3 – Matrices d'évaluation[44]

2.5 Les travaux de recherche basés sur l'architecture CNN pour la classification des tumeurs cérébrales

Avant d'arriver à notre solution, nous avons vu ce que d'autres chercheurs ont fait pour la classification des tumeurs cérébrales à partir des images IRM. Donc, nous allons présenter leurs principaux travaux ainsi que les différents datasets qu'ils ont utilisés . commençant par citer ces datasets :

2.5.1 Datasets des Images IRM Existants

- **BRAT 2015** [45] : c'est une dataset qui contient des images IRM du cerveau, elle était collecté depuis plusieurs ressources, elle contient des deux types de classes : tumeur et non tumeur.
- Une dataset depuis figshare [46], elle contient des 3064 images IRM du cerveau, elle permet la classification des 3 types de tumeurs cérébrales, Meningiome (708 images), Gliome (1426images), et tumeurs Hypophysaires (930 images). ces images sous format .mat .
- Une data set depuis Kaggle qui contient 253 images IRM du cerveau [47], elle permet une classification binaire; la classe non tumeur contient 98 images , et la classe tumeur contient 155 images.
- une dataset depuis kaggle qui contient 3000 images IRM [48], permet une classification binaire; les deux classes tumeur et non tumeur sont équilibrés(1500images pour chacune).
- Une dataset depuis le site de kaggle contient 3264 images et permet une classification multiclassés(4classes) [49], cette dataset est divisée en deux sous ensembles; ensemble d'entraînement (80%) et un ensemble de test (20%).

2.5.2 Travaux Connexes

Nous allons citer quelques recherches réalisées sur ce thème de classification :

1. En Septembre 2018, **J.Seetha et S.Selvakumar Raja** [50] : ont utilisé le dataset BRATS 2015 [45] pour une classification binaire (tumeur et non tumeur), ils ont proposé une architecture CNN, cette recherche a atteint une accuracy d'entraîne-

ment de 97.5 %

2. En Octobre 2018, **Ali pashaei ,Hedieh sajadi et Niloofar jazayeri [51]** : ont traité le même thème, ils ont utilisé un dataset depuis figshare [46] pour classer les tumeurs en 3 classes, ils ont proposé deux méthodes, la première consiste à utiliser des CNN, qui se composaient de 4 couches de convolution, 4 couches de pooling et 1 couche entièrement connectée. Et la deuxième consiste à combiner entre CNN et Kernal ELEM (KLEM).

Cette recherche a atteint une accuracy de de 81,09% pour la première méthode et 93,68% pour la deuxième méthode.

3. En 2019, **S.Deepak, P.M.Ameer [52]** : ont proposé le concept de CNN basé sur le deep transfer learning et cela en utilisant l'architecture GoogleNet pour l'extraction des images IRM du cerveau, afin de différencier les 3 types de tumeur cérébrale Gliomes, Méningiomes et tumeurs Hypophysaires , ils ont utilisés une dataset depuis figshare [46]. Cette approche a enregistré une Accuracy de 97.1% .

4. En 2020, **MilicaM. Badza and Marko C.Barjaktarovic [69]** : ont proposé une architecture CNN from scratch : 4 couches de convolution, 4 couches MaxPooling, 4couches Dropout, un couche Fully Connected et ils ont appliqués également une fonction d'activation, cette architecture été basée sur la méthode Cross-validation ou K=10. Ils ont utilisé le dataset [46] pour la classification de trois type de tumeurs et ils atteint une accuracy de 96.56%.

5. En 2020, **Navid Ghassemia, Afshin Shoeibi, Modjtaba Rouhania [54]** : ont traité le même thème à fin de classifier les TC en trois types Gliomes, Méningiomes et tumeurs Hypophysaires, ils ont utilisé deux datasets, la première est adressée à l'entraînement et l'évolution[46], elle inclue les trois plans d'images IRM (axial, sagittal et coronal). La deuxième dataset contient 373 images, l'assemblage de ces deux datasets est utilisée pour pré-entraîner le réseau GAN, et grâce à ce dernier ils ont obtenue des images de taille 64 X 64 .

Cette recherche a atteint une accuracy de 93.1 % pour la fraction introduit (introduced split) et 95.6% sur la fraction aléatoire(random split).

6. En même année, **Yakub Bhanothu, Anandhanarayanan Kamalakannan, Govindaraj Rajamanickam [55]** : ont traité le thème de la classification des TC en utilisant une méthode implémentée à l'aide de l'algorithme Faster R-CNN,

L'architecture VGG-16 a été choisie comme réseau de base dans Faster R-CNN. Cette méthode a été appliquée sur un dataset de 2406 images IRM en T1, ils ont atteint une précision de 75,18% pour le gliome, 89,45% pour le méningiome et 68,18% pour les tumeurs hypophysaires et une précision moyenne de 77,60% .

7. En même temps, **Ahmet Cinar, Muhammed Yildirim [70]** : ont proposé un modèle hybride développé avec l'architecture Resnet50 quelques couches de CNN ont été ajoutées, le dataset qu'ils ont utilisé contient 253 pour la classification binaire des images IRM de TC, cette étude a atteint une accuracy de 97.01% .
8. En 2021, **Francisco Javier Díaz-Pernas, Mario Martínez-Zarzuela, Míriam Antón-Rodríguez et David González-Ortega [56]** : ont proposé une méthode basée sur une architecture CNN pour un traitement multi-échelle afin d'effectuer la classification de 3 types de tumeurs (le méningiome, le gliome et les tumeurs de l'hypophyse), ils ont utilisé un dataset depuis figshare [46]. Cette recherche a atteint une accuracy de 97.3%
9. En même année, **Alaa Ahmed Abbood, Qahtan Makki Shallal, Mohammed A. Fadhel [57]** : ont utilisé ces quatre modèles pré-entraînés : AlexNet, VGG16, GoogleNet et ResNet50, ils ont utilisé le dataset de 3000 images IRM de tumeurs cérébrales pour une classification binaire (1800 images tumorales et 1200 images non-tumorales), les meilleurs résultats obtenus sont atteints par le modèle ResNET (Accuracy de 95.8%).
10. **En même année, Jaeyong Kang, Zahid Ullah et Jeonghwan Gwak [58]** : ont proposé une méthode en se basant sur le TL, cette méthode consiste à utiliser 13 différents réseaux pré-entraînés pour l'extraction des caractéristiques, et 9 différents types de ML pour la classification des tumeurs cérébrales, ces modèles seront testés sur 3 différents datasets : [47] , [48] et [49].
cette étude a démontré que l'utilisation de modèle pré-entraîné Dense169 avec SVM sur un dataset de 4 classes (normal, gliome, méningiome et tumeur hypophysaire) a atteint une accuracy de 92.04%.

2.5.3 Comparaison entre les travaux

Articles et Année	dataset	Méthode	Résultat
[50], 2018	BRATS 2015 [45], classification binaire	architecture CNN.	Accuracy d'entraîne- ment 97.5 %
[51], 2018	[46], de 3 classes	CNN CNN et KLEM	Accuracy de 81,09 % Accuracy : 93,68%
[52],2019	[46], de 3 classes	GoogleNet	Accuracy : 97.1%
[69],2020	[46], de 3 classes	CNN From scratch	Accuracy : de 96.56 %
[54],2020	[46], et le dataset de 373 images	GAN : Random Split	Accuracy : 95.6 %
[55],2020	2406 images IRM en T1	VGG-16 ET Faster R-CNN	Precision moyenne : 77,60%
[70],2021	253 images IRM pour une classification bi- naire	ResNet+CNN	Accuracy de 97.01 %
[56],2021	[46] de 3 classes	CNN	Accuracy de 97.3%
[57],2021	3000 images IRM pour la classification binaire,	ResNet50	Accuracy : 95.8%
[58], 2021	[49]	DenseNet169+ SVM	Accuracy de 92.08%

2.6 Conclusion

Dans ce chapitre nous avons présenté le machine learning et ses différents types d'apprentissage.

Ensuite, nous avons présenté le deep learning et ses algorithmes, puis nous avons détaillé sur le réseau de neurone convolutif (cnn) et nous avons déterminé la différences entre le deep learning et machine learning et les différentes métriques d'évaluation.

Enfin, nous avons présenté quelques travaux connexes qui ont été utilisés pour la classification des tumeurs cérébrales à partir des images IRM.

Dans le chapitre suivant, nous allons présenté notre solution proposée.

Approche et Solution Proposée

3.1 Introduction

Le développement de l'IA ne cesse pas de s'accroître de plus en plus, cette technologie a des impacts significatifs dans le domaine médical et notamment dans l'imagerie médicale, par conséquent le deep learning, il a permis la classification et la détection des images IRM pathologiques afin d'avoir un accès à un diagnostic rapide et précis en utilisant les réseaux de neurones convolutifs.

Dans ce chapitre, nous allons détailler notre solution proposée.

3.2 Architecture Globale de Notre Proposition

Dans ce travail, nous allons présenter quatre différentes approches en utilisant différents modèles pré-entraînés pour l'extraction de caractéristiques, par ailleurs la classification de ces caractéristiques s'effectue en appliquant la couche entièrement connectée (FC) et l'algorithme de machine learning SVM, ensuite on passe à la prédiction des images IRM. Et la figure **3.1**, illustre l'architecture globale de notre solution.

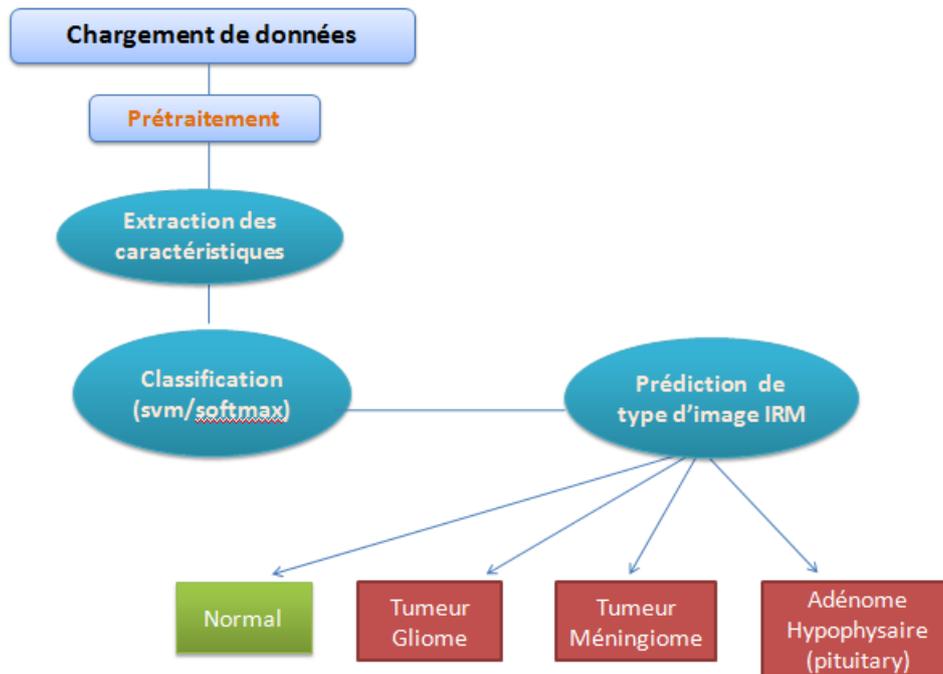


FIGURE 3.1 – L'architecture globale de la solution.

Notre proposition (Solution) c'est concrétisée en suivant les étapes déjà mentionner sur l'architecture précédante.

maintenant, on va détaillé chaque étape en citant les différentes matériels et méthodes utilisés

3.2.1 Dataset

Quand la tumeur cérébrales se développe dans le crane d'une personne cela peut provoquer la mort, pour des raisons personnels plusieurs patient ne veulent pas dévoiler leurs maladies et n'acceptent pas que leurs informations soient utilisées dans la recherche scientifique. Par conséquent, cela nous a empêché de trouver une dataset qui contient un nombre de données important.

Pour réaliser notre travail, on a dû choisir un dataset de 3264 images IRM qui est disponible publiquement sur le site de kaggle, intitulé « Brain Tumor Classification(MRI) [44], cette dernière contient 4 classes ; tumeur gliome (926 images), tumeur méningiome (937 images), adénome hypophysaire (901 images) et normal (500 images).

les images de cette dataset sont de taille (512*512 pixels) sous format (jpg).

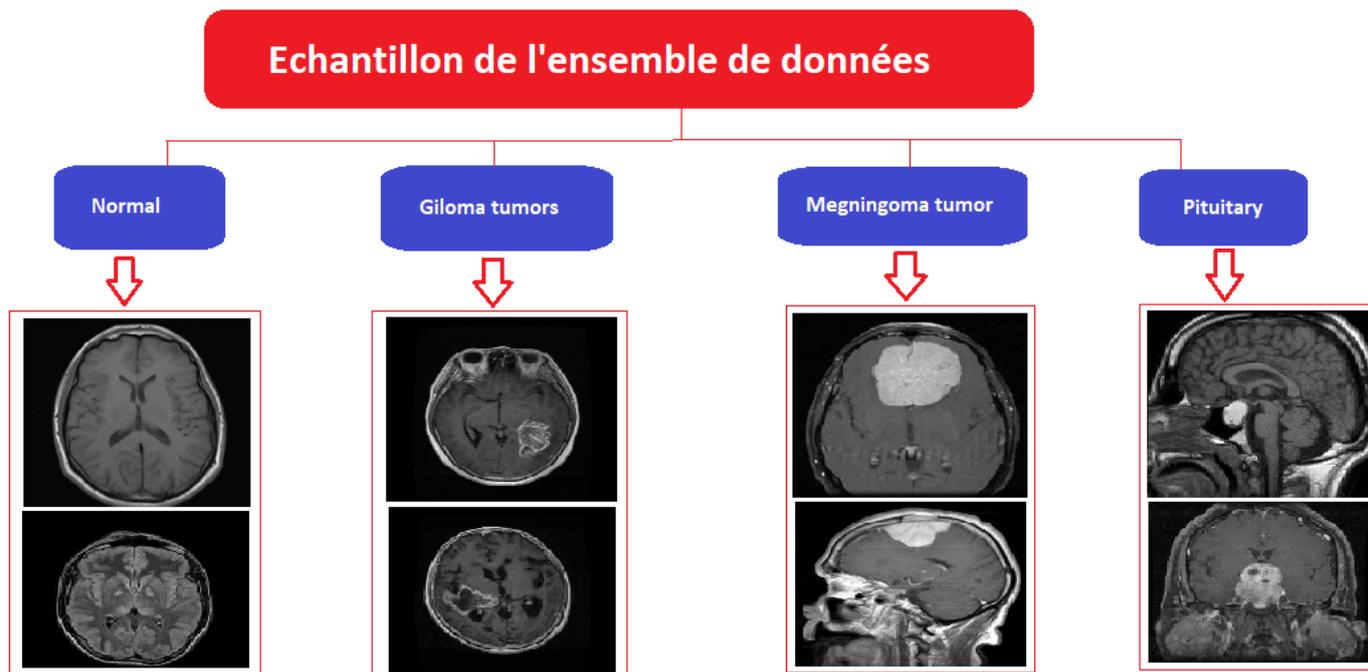


FIGURE 3.2 – Exemples de chaque type de tumeurs à partir d'IRM

Cet ensemble de données sera ensuite divisée en trois classes : tumeur gliome(926 images), tumeur méningiome(937 images) et pituitary (901 images) et le tableaux suivant représente sa répartition.

Ensemble de données	Nombre d'image
Ensemble d'Entrainement	1989
Ensemble de Validation	498
Ensemble de Test	277
Total	2764

TABLE 3.1 – Répartition des données de 3 classes

3.2.2 Visualisation de Données

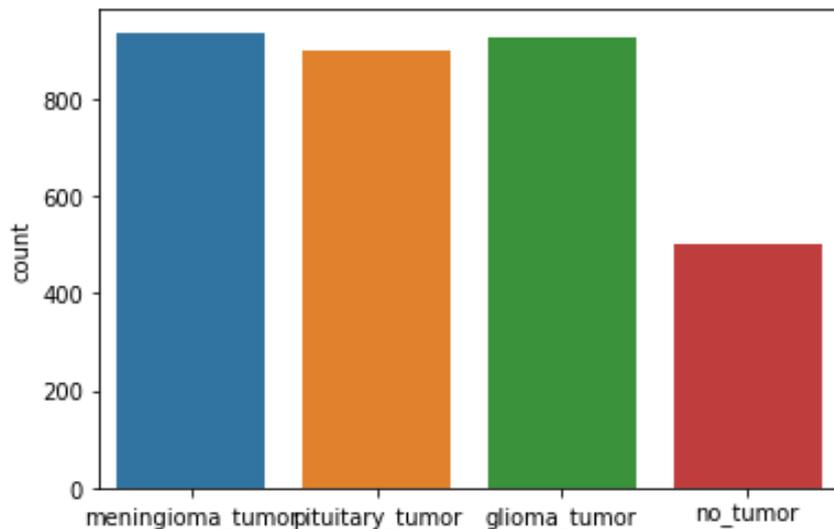


FIGURE 3.3 – Visualisation des données

3.2.3 Préparation de Données

Les images seront divisées en 3 sous-ensembles importants :

1. **Ensemble d'entraînement (Train set)** : 70 % des données seront utilisées dans la phase d'entraînement.
2. **Ensemble de validation (Validation set)** : 20 % des données seront utilisées dans la phase de validation.
3. **Ensembles de test (Test set)** : 10 % des données seront utilisées dans la phase de test.

Ensemble de données	Nombre d'image
Ensemble d'Entraînement	2349
Ensemble de Validation	588
Ensemble de Test	327
Total	3264

TABLE 3.2 – Représentation de données

3.2.4 Augmentation de Données

Afin qu'un modèle atteigne une bonne performance, il est nécessaire d'utiliser un ensemble de données volumineux, autrement dit plus on dispose d'une grande quantité de données plus le modèle s'entraîne mieux.

Cependant, l'augmentation de données est une technique qui permet d'enrichir les données d'entraînement ainsi que de résoudre le problème du déséquilibre des classes en effectuant diverses manipulations [53].

dans notre travail, on a augmenté les images durant l'entraînement en utilisant différentes techniques comme :

- rotation-range=10.
- zoom-range=0.1.
- width-shift-range=0.1 .

3.3 Entraînement de Nos Modèles

Vue qu'on travaille sur un dataset qui contient une faible quantité d'images IRM(3264 images IRM) et vu que notre objectif est d'avoir une bonne Accuracy cela nous a poussé à utiliser le transfer learning, qu'on l'a déjà présenté dans le deuxième chapitre.

Pour l'entraînement de nos modèles nous avons choisi une fonction de perte un optimiseur et des classificateurs et d'autres paramètres :

3.3.1 Fonction de Perte et d'optimisation

Afin de compiler un modèle, on devra choisir une fonction de perte et un optimiseur. Cependant, La fonction de perte est la quantité qui sera minimisée pendant la formation (entraînement). En outre L'optimiseur détermine comment le réseau sera mis à jour en fonction de la fonction de perte [59].

Pour nos modèles, on a choisi ces deux fonctions :

Adam : c'est une méthode efficace en terme de calcul, a peu de besoin en mémoire, et invariante à la remise à l'échelle diagonale des gradients,et elle est bien adaptée aux problèmes qui sont grands en termes de données et/ou paramètres [60].

Categorical Crossentropy : utilisée pour les problème de classification multiclassé[59].

3.3.2 Le Classificateur Softmax

appelée également softargmax, ou régression logistique multi-classes, c'est une généralisation de la régression logistique qui peut être utilisée pour la classification multi-classes [61]. Cependant cette fonction transforme un vecteur de K valeurs réelles en un vecteur de K valeurs réelles dont la somme est égale à 1. Les valeurs d'entrée peuvent être positives, négatives, nulles ou supérieures à 1, mais la fonction softmax les transforme en valeurs comprises entre 0 et 1, afin qu'elles puissent être interprétées comme des probabilités. Si l'une des entrées est petite ou négative, le softmax la transforme en une petite probabilité, et si une entrée est grande, alors il la transforme en une grande probabilité, mais elle restera toujours entre 0 et 1 [61].

3.3.3 Classificateur SVM

L'algorithme SVM est parmi les algorithmes de ML qui promet d'avoir des bonne performance pour la classification des images. dans ce travail nous allons l'utiliser en appliquant le noyau(kernel) **RBF**.

3.3.4 Early Stopping

Permet d'arrêter l'entraînement lorsqu'une métrique a cessé de s'améliorer [62].

3.3.5 ReduceLROnPlateau

permet de réduire le taux d'apprentissage lorsqu'une métrique a cessé de s'améliorer, Les modèles bénéficient souvent d'une réduction du taux d'apprentissage d'un facteur de 2 à 10 lorsque l'apprentissage stagne. Cependant ce callback surveille une quantité et si aucune amélioration n'est constatée pendant un nombre d'époques 'patience', le taux d'apprentissage est réduit [63].

3.3.6 Checkpoint

Checkpoint ou point de contrôle en français désigne la sauvegarde instantané des paramètres d'un modèle (poids, son taux d'apprentissage actuel) après chaque époque d'apprentissage [64].

3.3.7 Création des Modèles

Après avoir présenter le dataset utilisé et le pré-traitement effectuer dans notre travail, on s'intéresse par la suite sur la partie d'extraction des caractéristiques et la classification selon le modèle utilisé.

Les modèles pré-entraîner que nous allons appliqués dans notre solution sont :

1. L'architecture DenseNet.
2. L'architecture Xception.

D'abord, avant de passer à la création de chaque modèle, nous devons les redéfinir afin d'avoir une vue plus rapprochée.

3.3.7.1 Description du Modèle DenseNet121

DenseNet121 [65] : C'est un modèle pré-entraîner sur l'ensemble de données d'**ImageNet**, c'est une version de modèle **DenseNet** et il contient 121 couches :

cinq couches de convolution et pooling, trois couches de transition, une couche de classification et deux blocs Dense.

le modèle **dense121** a été développé spécifiquement pour améliorer la précision déclinée par la disparition du gradient dans les réseaux neuronaux de haut niveau. En termes plus simples, en raison du chemin plus long entre la couche d'entrée et la couche de sortie, l'information disparaît avant d'atteindre sa destination.

- **Modèle 1** : Le modèle pré-entraîner Dense121 reçoit en entrée une image pré-traitée de taille (300*300*3) afin d'effectuer l'extraction des caractéristiques, la sortie de ce modèle sera ensuite émet vers la couche **GlobalAveragePooling**, cette couche prend la moyenne de chaque carte de caractéristique, elle est ensuite suivie d'une couche dense et d'une dropout avec un paramètre de 0.2 qui permet d'éviter l'overfitting.

Afin d'établir la classification on applique deux couches dense, la dernier utilise le

classificateur softmax avec 4 neurones.

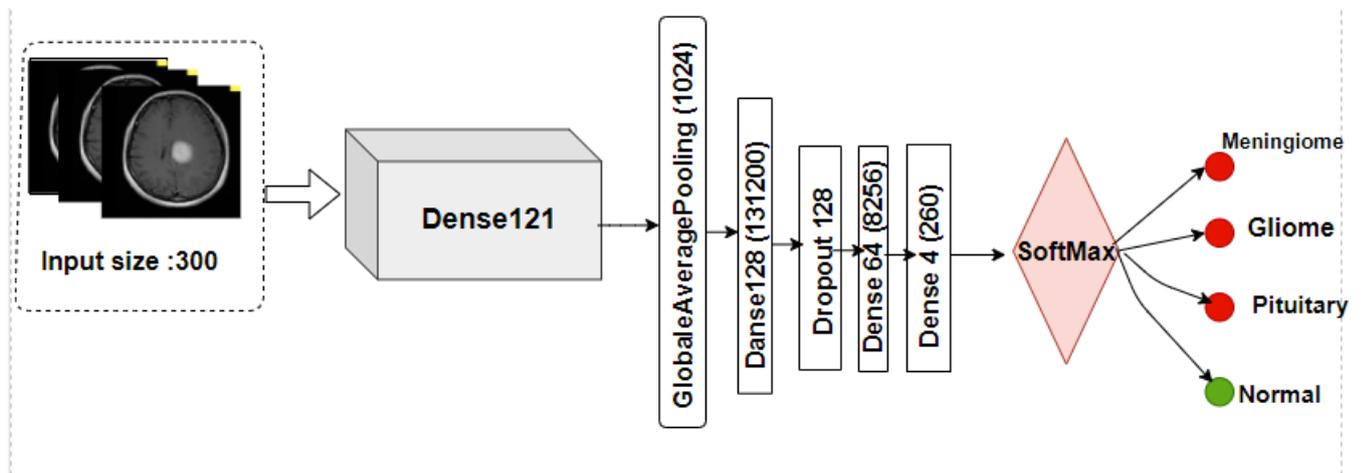


FIGURE 3.4 – Modèle basé sur DenseNet et Softmax.

- **Modèle 2** : ce modèle applique les mêmes couches que le modèle 1, sauf que la sortie de la dernière couche Dense sera intégrée dans le classificateur SVM en appliquant un noyau (kernel) RBF.

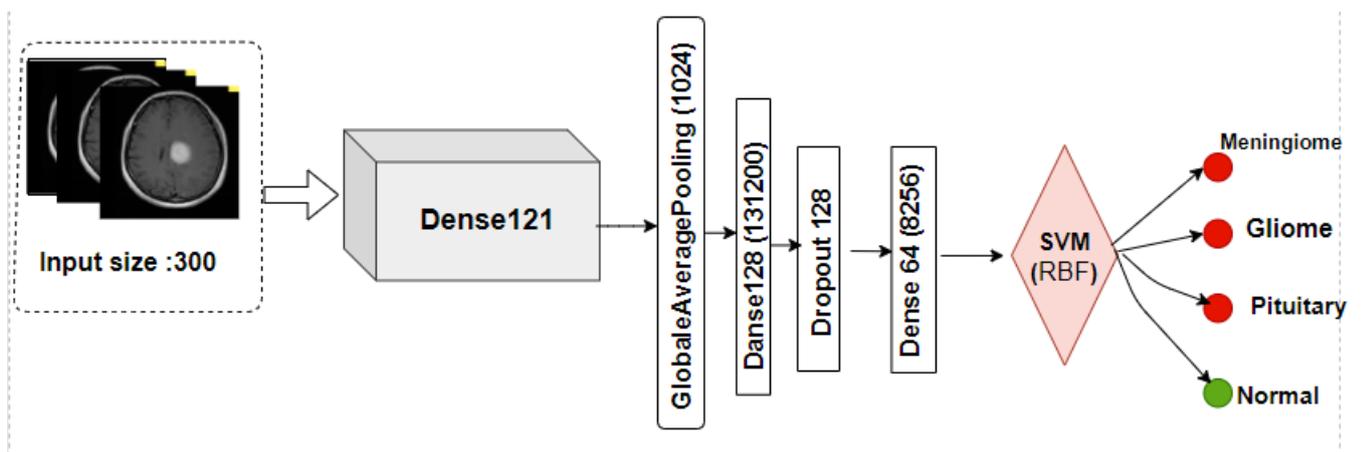


FIGURE 3.5 – Modèle basé sur DenseNet et SVM.

3.3.7.2 Description du Modèle Xception

Xception [38] : C'est un modèle pré-entraîné sur l'ensemble de données d'**ImageNet**, Il contient 36 couches convolutives permettant l'extraction des caractéristiques, elles sont structurées en 14 modules, ces derniers sont tous entourés d'une couche Relu sauf le premier et le dernier module. Il repose sur deux points principaux :

La convolution séparable en profondeur et les raccourcis entre les blocs de convolution[38].

- **Modèle 3** : le modèle **Xception** va extraire les caractéristiques de nos images **IRM**. D'abord, il prend comme entrée les images pré-traitées, ensuite, la sortie de ce modèle va être directement dans l'entrée de la couche suivante qui est le **GlobalAveragePooling**, après cette dernière couche on va appliquer une fonction d'activation (Relu) ainsi que le classificateur softmax.

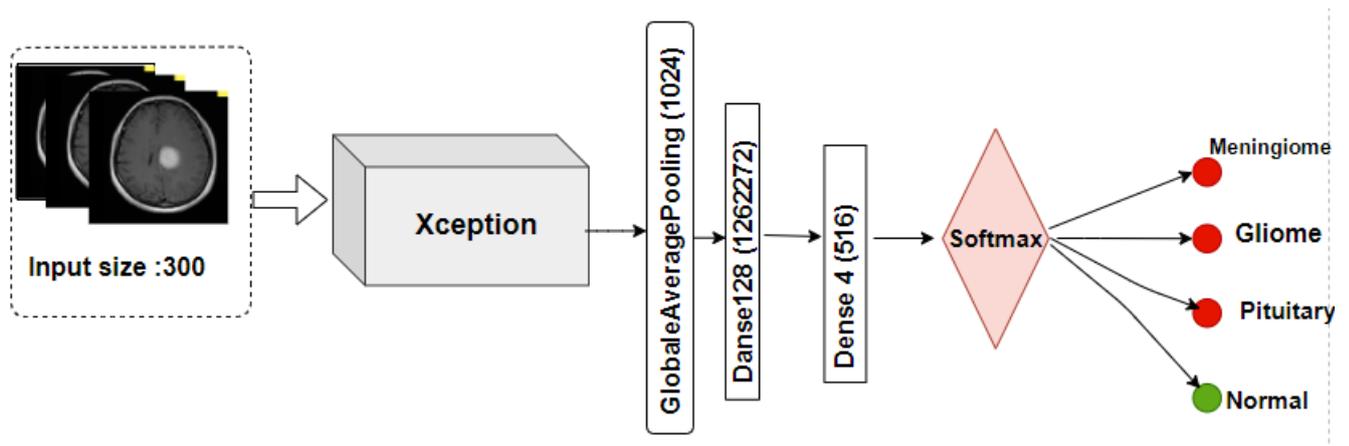


FIGURE 3.6 – Notre architecture basé sur le modèle Xception et le classificateur Softmax.

- **Modèle 4** : les mêmes couches que le modèle 3, sauf que ce modèle utilise le classificateur SVM qui applique un kernel RBF, ce classificateur reçoit en entrée la sortie de la couche GlobalAveragPooling.

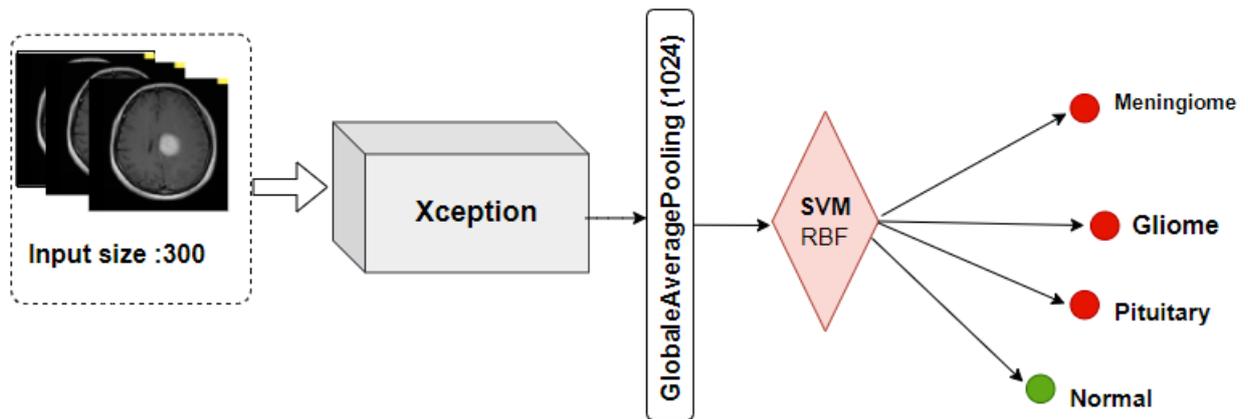


FIGURE 3.7 – Notre architecture basé sur le modèle Xception et le classificateur SVM.

3.4 Conclusion

Dans ce chapitre, nous avons détaillé notre proposition (solution) qui permet de résoudre notre problème, et cela, en présentant le dataset et les différentes méthodes qu'on a utilisé. Le chapitre suivant sera consacré à la discussion des résultats et les outils de programmation utilisés.

Chapitre 4

Résultat et Discussion

4.1 Introduction

Après avoir détailler notre approche dans le chapitre précédent, dans ce chapitre, nous allons parlé d'une manière plus claire sur l'environnement de programmation, le langage ainsi que les bibliothèques utilisées qui nous ont aidé à implémenter notre solution.

Par ailleurs, nous allons discuter en détails sur ce que nous avons obtenu comme résultats. Nous Conclurons par une comparaison pour chaque résultat obtenu.

4.2 Environnement de Programmation

4.2.1 Plateforme (Environnement) De Programmation

Google Colaboratory :¹ il est offert gratuitement par Google,il est basé sur Jupyter Notebook, cette dernière est une application web open source qui permet de créer et de partager des documents contenant des codes. l'utilisateur de cette plateforme n'aura besoin de rien installer sur son ordinateur car l'entraînement des modèles de machine learning soient effectués sur le cloud.

Google Colab contient deux modes d'exécution GPU et TPU qui lui ont permet d'avoir des résultats rapidement.

1. <https://colab.research.google.com>

4.2.2 Language De Programmation

Python est le langage de programmation le plus utilisé dans le domaine du Machine Learning, du Big Data et de la Data Science.

Python :

Il a été créé en 1991 par Guido van Rossum, aux Pays-Bas, il tire son nom de l'émission Monty Python's Flying Circus. Il a été apparu à l'époque comme une façon d'automatiser les éléments les plus ennuyeux de l'écriture de scripts. Il s'agit d'un langage de programmation interprété, qui ne nécessite donc pas d'être compilé pour fonctionner. Un programme "interpréteur" permet d'exécuter le code Python sur n'importe quel ordinateur. Ceci permet de voir rapidement les résultats d'un changement dans le code [66].

Le langage **Python** doit sa popularité à plusieurs avantages qui profitent aussi bien aux débutants qu'aux experts. Tout d'abord :

- Il est facile à apprendre et à utiliser. Ses caractéristiques sont peu nombreuses, ce qui permet de créer des programmes rapidement et avec peu d'efforts [66].
- Un autre avantage du Python est sa popularité. Ce langage fonctionne sur tous les principaux systèmes d'exploitation et plateformes informatiques. De plus, même s'il ne s'agit clairement pas du langage le plus rapide, il compense sa lenteur par sa versatilité [66].
- Enfin, même s'il est principalement utilisé pour le scripting et l'automatisation, ce langage est aussi utilisé pour créer des logiciels de qualité professionnelle [66].

4.3 Bibliothèques Utilisées

4.3.1 TensorFlow

Il a été développé par Google en 2015, il existait depuis 2011 sous le nom DistBlief qui était dédié aux réseaux de neurones du deep learning.

TensorFlow :² est une bibliothèque de machine learning qui permet de résoudre des problèmes mathématiques extrêmement complexes avec aisance, cette bibliothèque intègre des API de haut niveau de développement d'applications, cette dernière repose sur le langage de programmation Python. Il dispose de trois modes d'exécution CPU, GPU et

2. <https://www.lebigdata.fr/python-langage-definition>

TPU.

4.3.2 Keras

Il était développé par François Chollet, c'est une bibliothèque open source dédiée aux réseaux de neurones, et c'est une API de haut niveau écrite en python, cette bibliothèque a été intégré au TensorFlow depuis 2017 [67].

4.3.3 Matplotlib

Matplotlib³ C'est une bibliothèque open source de traçage Python 2D, son objectif est de générer des visualisation détailler sur les données en tapant juste quelques lignes de code.

4.3.4 Sklearn

C'est un module Python pour l'apprentissage automatique construit sur SciPy et est distribué sous la licence BSD à 3 clauses [68].

4.4 Résultats Obtenus

Dans cette sections nous allons présenté nos différents resultats obtenus durant l'entraînement ainsi que le test.

4.4.1 Phase d'Entraînement

Chaque modèle qu'on a proposé a été entrainer sur la dataset que l'on a déjà présenté dans le chapitre présidant, Ces modèles seront aussi entrainer sur le dataset de 3 classes.

Dans ce qui suit nous allons présenté les résultats obtenues pour chaque datasets.

3. <https://matplotlib.org/>

4.4.1.1 Résultats d'Entraînement pour la Classification 4 Classes

Le tableau 4.1 représente la performance d'entraînement de nos modèles pour la classification de 4 classes.

Modèles proposés	Accuracy	Loss
Xception+softmax	97.10 %	12.82 %
Xception+svm	97.10 %	/
Dense121+softmax	93.87 %	35.02 %
Dense121+svm	94.72%	/

TABLE 4.1 – Accuracy et loss d'entraînement de chaque modèle pour la classification 4 classes.

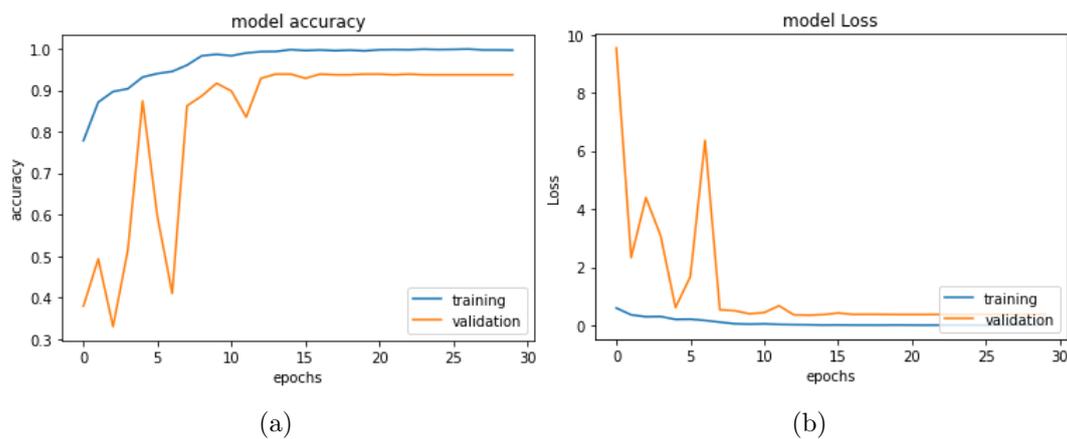


FIGURE 4.1 – Graphes accuracy et Loss en utilisant le modèle DenseNet121 durant 30 epoches sur 4 classes

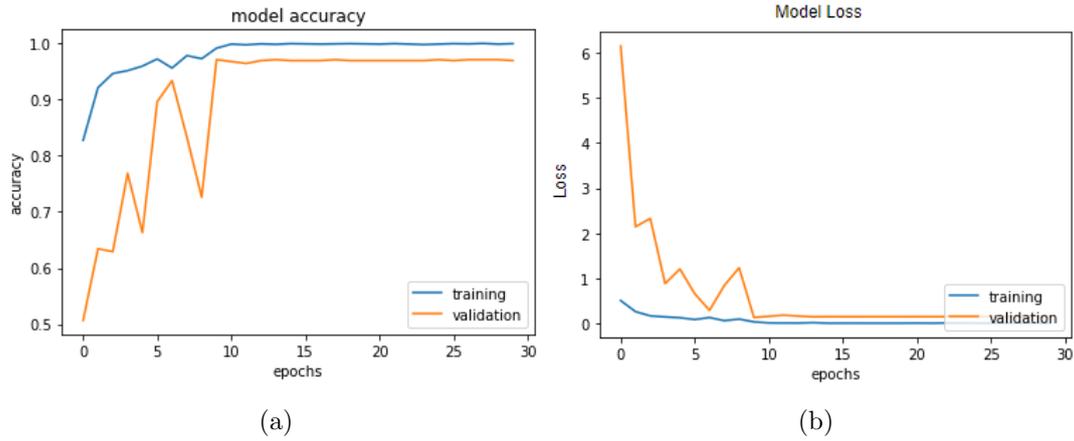


FIGURE 4.2 – Graphes accuracy et Loss en utilisant le modèle xception durant 30 epoches sur 4 classes

4.4.1.2 Résultats d'Entraînement pour la Classification 3 Classes

Modèles proposés	Accuracy	Loss
Xception+softmax	96.58 %	11.04 %
Xception+svm	97.59 %	/
Dense121+softmax	96.38 %	12.31 %
Dense121+svm	97.79 %	/

TABLE 4.2 – Accuracy et loss selon chaque modèle testé sur la datasets de 3 classes.

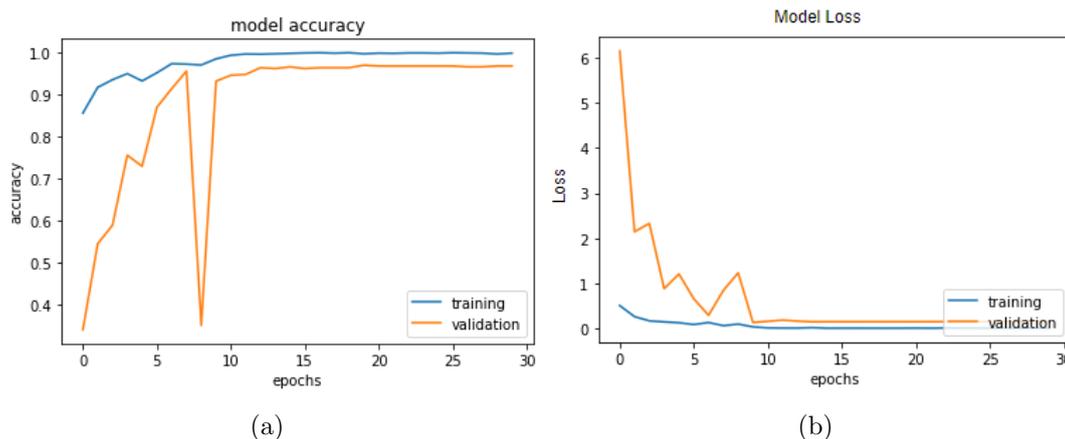


FIGURE 4.3 – Graphes accuracy et Loss en utilisant le modèle xception durant 30 epoches sur 3 classes

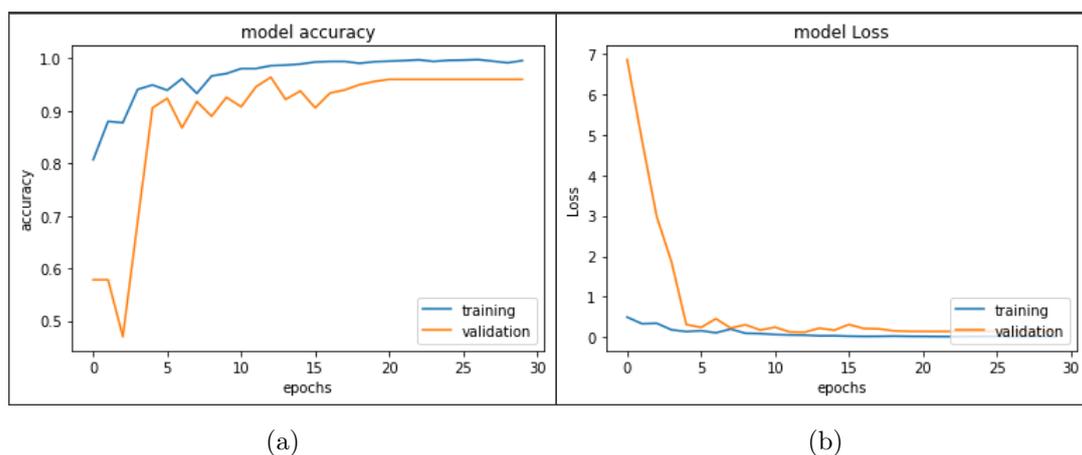


FIGURE 4.4 – Graphes accuracy et Loss en utilisant le modèle DensNet121 durant 30 epoches sur 3 classes

la table 4.2 représente la performance d’entraînement de nos modèles pour la classification de 3 classes.

les figures 4.1-4.4 montre les courbes d’accuracy et de perte sur les ensembles d’entraînement et de validation au cours des époques d’entraînement pour nos deux modèles basés sur dense121 et Xception pour la classification 4 classes et 3 classes . Ces graphiques illustrent que nos modèles proposés ont été parfaitement entraînés .

4.4.2 Résultats Obtenus Durant le Test

Nos résultats de la classification 4 classes et 3 classes ont été évolués en utilisant les métriques d'évaluation : Accuracy, Precision, F1-score et Recall.

les performances de nos modèles sont montrées dans les tables 4.3 et 4.4

Modèles proposés	Accuracy	Precision	F1-score	Recall
Xception+softmax	96.33%	96.26%	96.5%	96.72%
Xception+svm	96.33%	96.32%	96.49%	96.69%
Dense121+softmax	96.94%	97.08%	97.03%	97%
Dense121+svm	96.33%	96.58%	96.52%	96.47%

TABLE 4.3 – Résultats du test selon la detaset de 4 classes

Modèles proposés	Accuracy	Precision	F1-score	Recall
Xception+softmax	97.47%	97.45%	97.45%	97.47%
Xception+svm	97.47%	97.45%	97.45%	97.47%
Dense121+softmax	94.22%	94.28 %	94.19%	94.34%
Dense121+svm	94.94 %	94.92 %	94.92%	94.91%

TABLE 4.4 – Résultats du test selon la detaset de 3 classes

4.5 Analyse et Discussion

Dans cette section, nous allons comparé nos modèles proposer selon les résultats obtenus à partir des deux datasets afin de déterminer qui est le plus performant

4.5.1 Comparaison entre les Modèles Proposés

D'après les résultats obtenus durant le test, on constate que les modèles qu'on les a proposés donnent des bonnes résultats ($> 90\%$), mais il existe un modèle plus performant que les autres selon le nombres de classes de notre dataset utilisé.

Dans ce qui suit nous allons comparé les résultats obtenues selon chaque classes.

Selon le dataset de 4 classes :

Le modèle pré-entraîner **DenseNet121** est performant en l'utilisant avec le classifieur softmax.

Modèles proposés	Acurracy	Precision	F1-score	Recall
Dense121+softmax	96.94%	97.08%	97.03%	97%

TABLE 4.5 – Modèle performant sur le dataset de 4 classes

Selon le dataset de 3 classes :

Le modèle pré-entraîner Xception est performant en l'utilisant avec le classificateur softmax ou bien SVM avec le karnel (RBF).

Modèles proposés	Acurracy	Precision	F1-score	Recall
Xception+softmax	97.47%	97.45%	97.45%	97.47%
Xception+svm	97.47%	97.45%	97.45%	97.47%

TABLE 4.6 – Modèles performant sur la dataset de 3 classes

4.5.2 Comparaison avec d'autres Travaux de la Littérature

Les tables 4.7 et 4.8 représentent la comparaison de nos modèles proposés avec d'autres travaux de la littérature pour la classification 4 classes et 3 classes respectivement.

Selon 4 classes :

Recherche	Accuracy	Precision	Recall	F1-Score
2021,DenseNet169 +SVM [58]	92.08%	Pas mentionner	Pas mentionner	Pas mentionner
Notre modèle proposé (basé sur Dense- Net121+softmax)	96.94%	97.08%	97.03%	97%

TABLE 4.7 – Comparaison entre notre modèle proposé (DenseNet121+SVM) et un travail de littérature.



FIGURE 4.5 – Comparaison entre notre modèle Dense121+softmax et le modèle de travaux de littérature Dense169+svm

Notre modèle a été entraîné sur un ensemble de données avec un nombre de classes de tumeur cérébrale similaire à celui effectué sur le modèle DenseNet169+SVM, vu qu'on a utilisé le même dataset.

On remarque que notre modèle proposé Densnet121+Softmax a obtenu de meilleurs résultats en termes d'accuracy 96.94 %, ce qui représente une énorme amélioration en termes de calcul et performance .

Selon 3 classes :

Recherche	Accuracy	Precision	Recall	F1-Score
2020, GAN basé sur random split. [54]	95.60%	95.29%	Pas mentionner	95.10%
Notre modèle proposé (basé sur Xception+softmax/SVM)	97.47%	97.45%	97.45%	97.47%

TABLE 4.8 – Comparaison entre notre modèle proposé(Xception+Softmaw/SVM)et un travail de littérature .

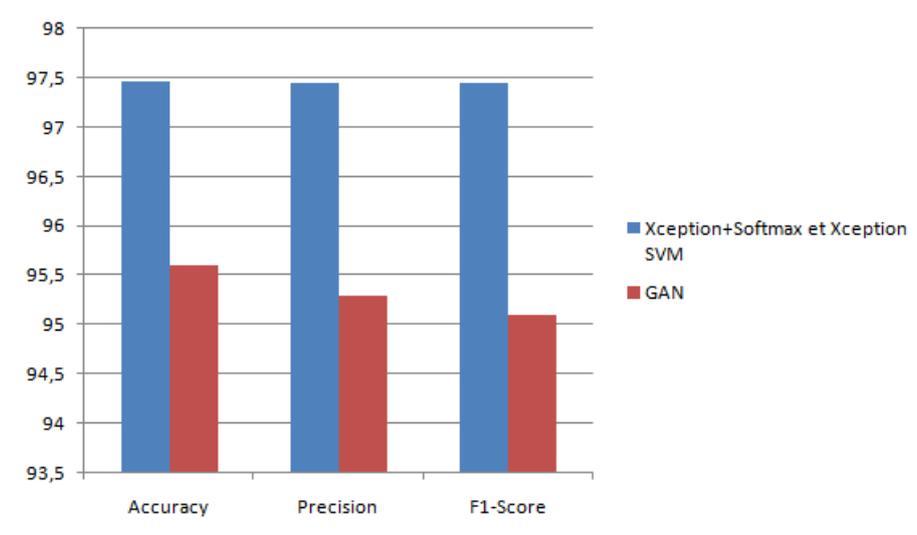


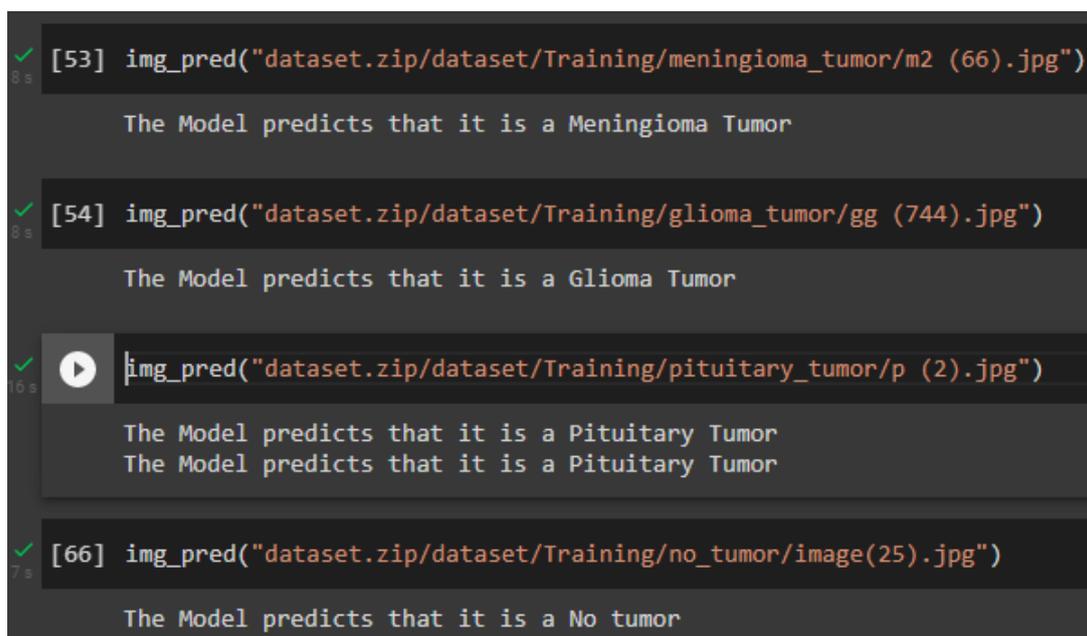
FIGURE 4.6 – Comparaison entre les modèles xception+softmax/svm et GAN

Notre modèle a été entraîné sur un ensemble de données avec un nombre de classes similaire à celui utilisé sur le modèle GAN.

On remarque que selon 3 classes notre modèle proposé Xception+Softmaw/SVM a obtenu des meilleurs résultats en termes d'accuracy 97.47 %, ce qui représente une énorme amélioration en termes de calcul et performance.

4.6 Prédiction de Nos Modèles

Après qu'on avait constater que le modèle DenseNet121+softmax donnent des meilleurs résultats avec une accuracy de 96.94 %, ainsi que le modèle Xception+softmax/SVM avec une accuracy de 97.47 %, on a choisit des images IRM de tumeurs cérébrales aléatoirement et on les a testé sur ces modèles, et les figures 4.7 et 4.8 suivantes représentent leurs prédiction pour une classification de 4 classes et 3 classes :



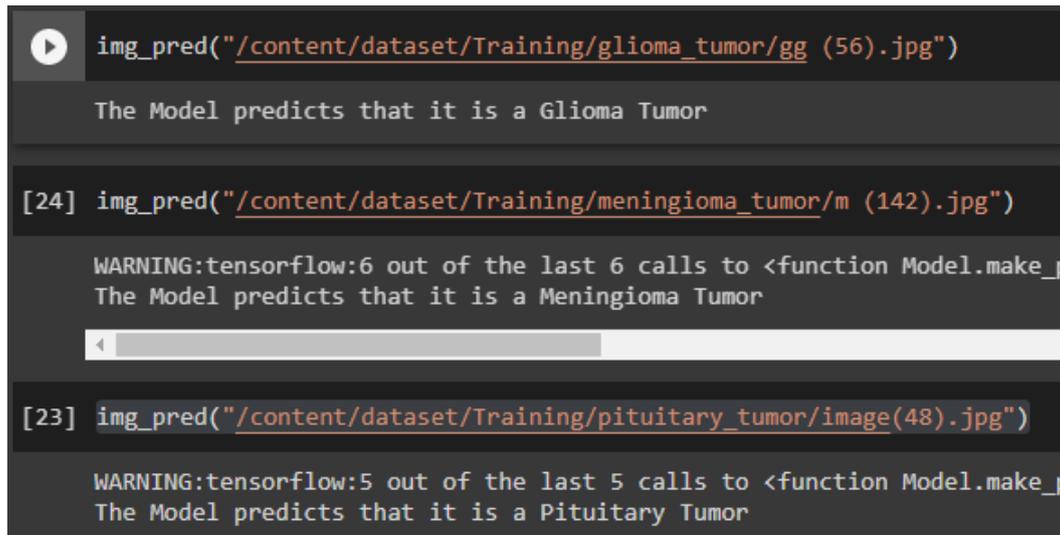
```
[53] img_pred("dataset.zip/dataset/Training/meningioma_tumor/m2 (66).jpg")
The Model predicts that it is a Meningioma Tumor

[54] img_pred("dataset.zip/dataset/Training/glioma_tumor/gg (744).jpg")
The Model predicts that it is a Glioma Tumor

[55] img_pred("dataset.zip/dataset/Training/pituitary_tumor/p (2).jpg")
The Model predicts that it is a Pituitary Tumor
The Model predicts that it is a Pituitary Tumor

[66] img_pred("dataset.zip/dataset/Training/no_tumor/image(25).jpg")
The Model predicts that it is a No tumor
```

FIGURE 4.7 – Prédiction du modèle DenseNet+Softmax pour une classification de 4 classes



```
▶ img_pred("/content/dataset/Training/glioma_tumor/gg (56).jpg")
The Model predicts that it is a Glioma Tumor

[24] img_pred("/content/dataset/Training/meningioma_tumor/m (142).jpg")
WARNING:tensorflow:6 out of the last 6 calls to <function Model.make_p
The Model predicts that it is a Meningioma Tumor

[23] img_pred("/content/dataset/Training/pituitary_tumor/image(48).jpg")
WARNING:tensorflow:5 out of the last 5 calls to <function Model.make_p
The Model predicts that it is a Pituitary Tumor
```

FIGURE 4.8 – Prédiction du modèle xception+softmax/svm pour une classification de 3 classes

4.7 Conclusion

Nous avons présenté dans ce dernier chapitre les différents langages et outils de programmation que nous avons utilisés afin d'implémenter notre solution. Ensuite, nous avons comparé les différents modèles qu'on a créés. Enfin, nous avons comparé nos modèles avec quelques travaux de littératures.

Conclusion générale et Perspectives

Lors de l'élaboration de notre projet, l'objectif ultime est d'améliorer la performance et l'accuracy d'un modèle en utilisant les différentes techniques de deep learning ainsi que le machine learning.

Les modèles que nous avons proposés permettent la classification des tumeurs cérébrales en 4 classes : normal, tumeur gliome, méningiome et adénome hypophysaire.

Nous avons présenté les parties essentielles de la réalisation de notre projet qui sont : pré-traitement de données, l'extraction des caractéristiques et la classification.

Afin d'arriver à notre objectif, nous avons testé et validé notre modèle proposé sur deux data-sets : une contient 4 classes, et l'autre contient 3 classes de tumeurs cérébrales, en utilisant deux modèles pré-entraînés et 2 types de classifieurs (FC et SVM).

Après toutes les expériences que nous avons faites durant ce travail on constate que les modèles que nous avons proposés donnent de bons résultats, Or selon le critère nombre de classes, il existe un plus performant que les autres modèles.

Pour la classification de 4 classes le modèle DenseNet121+ Softmax est performant avec une accuracy de 96.94%, et pour la classification 3 classes le modèle xception+ SVM ainsi que Xception+softmax sont performants avec une accuracy de 97.47%.

Perspective :

En ce qui concerne les travaux futures, nous avons l'intention d'étendre ce travail pour l'expérimenter avec de plus grands ensembles de données et d'autres types de tumeurs ainsi que d'utiliser d'autres techniques comme la validation croisée(Cross Validation).

Bibliographie

- [1] N.CHAHER, N. (s.d.). Généralité sur les tumeurs .
- [2] J.-F. Mosnier, A. L.-F. (2007, Mais). Généralités sur les tumeurs (Chapitre7) .
- [3] <https://sante.journaldesfemmes.fr/fiches-maladies/2651843-cancer-secondaire-foie-poumon-symptomes-cause-diagnostic-traitement-esperance-de-vie-pronostic/>, consulté le 08/09/2021.
- [4] LES TUMEURS DE CERVEAU, guide patient, juin2010.
- [5] fondtion ARC pour la recherche sur le cancer . (s.d.). Les cancers du cerveau.
- [6] Les tumeurs gliales diffuses de l'adulte,Hétérogénéité génétique et implications thérapeutiques,Maïté Verreault1,2,3, Jean-Yves Delattre1,2,3,4, Ahmed Idbaih1 <https://doi.org/10.1051/medsci/20122810005>.
- [7] Bendib, M. M. (2014/2015). Thèse Présentée en vue de l'obtention du diplôme de Doctorat 3ème Cycle LMD. Détection de pathologies à partir. ANNABA, Département d'Informatique, Faculté des Sciences de l'ingénieur, ALGERIE.
- [8] Louis-David RIVIERE, Le 30 octobre 2015, THESE POUR LE DIPLOME D'ETAT DE DOCTEUR EN MEDECINE, MEDECINE SPECIALISEE CLINIQUE, ETUDE EN IRM DES MACROADENOMES HYPOPHYSAIRES CORTICOTROPES SILENCIEUX, UNIVERSITE TOULOUSE III – PAUL SABATIER.
- [9] <http://www.radcoursorg.be/INF02/page1/files/CHAP/201/20et/202/202018>.
- [10] B Kastler, P Anstett, B Kastler, D Vetter - 2011 - Elsevier.
- [11] <https://tpelyceeblaisepascalorsayirm.wordpress.com/2016/04/18/lappareil-irm-standard/>, consulter le 09/09/2021.

- [12] Barbara Leh, soutenue le 17 octobre 2011, Thèse pour obtenir le titre de Docteur ès Sciences de l'Université Paris Sud, Caractérisation par autofluorescence de tissus cérébraux tumoraux.
- [13] <http://openaccess.kavram.edu.tr/xmlui/bitstream/handle/20.500.12569/240/Hakan-Burcin-Erdogus.pdf?sequence=1/isAllowed=y>
- [14] Olivier Le Cadet, Thèse :Classification de textures pour la caractérisation de tumeurs cérébrales, Region Rh^{one}-Alpes.
- [15] Mathieu SINIGAGLIA, THÈSE POUR LE DIPLÔME D'ÉTAT DE DOCTEUR EN MÉDECINE MÉDECINE SPÉCIALISÉE CLINIQUE, Efficacité diagnostique et pronostique de la 18F-Fluoro-ethyl-L-tyrosine (18FFET)TEP TDM dans la prise en charge des gliomes hémisphériques de l'adulte classés bas grade à l'IRM initiale.
- [16] Mr. Abdelali El MATLINI, THÈSE PRÉSENTÉE ET SOUTENUE PUBLIQUEMENT LE 04/02/2019, Prise en charge des tumeurs cérébrales chez les sujets de plus de 70 ans : expérience du service de neurochirurgie de l'hôpital Arrazi.
- [17] Navid Ghassemia, Afshin Shoeibia, Modjtaba Rouhania, Deep neural network with generative adversarial networks pre-training for brain tumor classification based on MR images Navid.
- [18] Deep Learning with python, François Chollet.
- [19] Deep Learning on windows, Building deep learning computer vision, Systeme on microsoft windows, THIMIRA Amaratunga.
- [20] Introduction au Machine Learning Chloé-Agathe Azencott.
- [21] A State-of-the-Art Survey on Deep Learning Theory and Architectures.
- [22] <https://dataanalyticspost.com/Lexique/svm/>
- [23] Al-Anazi, A., and I. D. Gates. "A support vector machine algorithm to classify lithofacies and model permeability in heterogeneous reservoirs." *Engineering Geology* 114.3-4 : 267-277. (2010).
- [24] <https://eric.univ-lyon2.fr>.
- [25] Karim Aderghal. Classification of multimodal MRI images using Deep Learning : Application to the diagnosis of Alzheimer's disease, Hal, France, 2021.
- [26] <https://www.researchgate.net/figure/Structure-de-modele-de-reseau-de-neurones-artificiels-fig5-322263283>.

- [27] Machine Learning and Deep Learning Methods for Cybersecurity, DOI :10.1109.
- [28] Cours Big data et deep learning, Dr Saadna yassmina.
- [29] <https://www.seekpng.com/ipng/u2w7o0r5y3a9y3e6-deep-learning-performance-deep-learning-vs-machine-learning/>
- [30] <https://www.jigsawacademy.com/machine-learning-model-vs-deep-learning-case-study-approach/>, consulté le 19/08/2021.
- [31] <http://staff.univ-batna2.dz/sites/default/files/merzougui-ghalia/files/support-de-cours-deep-learning-chapitre3-cnn.pdf>, consulter le 19/08/2021.
- [32] <https://www.sciencedirect.com/science/article/pii/S177698171930063X>, consulté le 19/08/2021.
- [33] <https://docplayer.fr/169644391-Par-firas-ben-dhaou-montreal-le-13-aout-2019-ecole-de-technologie-superieure-universite-du-quebec.html>, consulté le 19/08/2021.
- [34] <https://ichi.pro/fr/un-guide-complet-des-reseaux-de-neurones-convolutifs-la-methode-eli5-65776100198995>, consulté le 19/08/2021.
- [35] Karen Simonyan and Andrew Zisserman, Visual Geometry Group, Department of Engineering Science, University of Oxford, VERY DEEP CONVOLUTIONAL NETWORKS FOR LARGE-SCALE IMAGE RECOGNITION, Published as a conference paper at ICLR 2015, consulté le 8/10/2021.
- [36] Kaiming He Xiangyu and Zhang Shaoqing and Ren Jian Sun, Microsoft Research, Deep Residual Learning for Image Recognition, consulté le 8/10/2021.
- [37] Gao Huang Cornell University, Zhuang Liu Tsinghua University, Laurens van der Maaten Facebook AI Research, Densely Connected Convolutional Networks, consulté le 8/10/2021.
- [38] François Chollet, Google, Inc, Xception : Deep Learning with Depthwise Separable Convolutions, consulté le 8/10/2021.
- [39] A Survey on Prevention of Overfitting in Convolution Neural Networks Using Machine Learning Techniques.
- [40] <https://datascientest.com/events>.
- [41] Transfer Learning With Adaptive Fine-Tuning, GREGA VRBAN , (Graduate Student Member, IEEE), AND VILI PODGORELEC , (Member, IEEE).

- [42] Classification of Dental Diseases Using CNN and Transfer Learning, Shreyansh A. Prajapati, R. Nagaraj and Suman Mitra.
- [43] <https://analyticsindiamag.com/10-model-evaluation-techniques-every-machinelearning-enthusiast-must-know/>, avril 2019.
- [44] <https://blog.exsilio.com/all/accuracy-precision-recall-f1-score-interpretation-of-performance-measures/>.
- [45] dataset BRATS 2015, <https://www.smir.ch/BRATS/Start2015>.
- [46] figshare dataset, <https://doi.org/10.6084/m9.figshare.1512427.v5>.
- [47] <https://www.kaggle.com/navoneel/brain-mri-images-for-brain-tumor-detection>, consulté le 03/09/2021.
- [48] <https://www.kaggle.com/ahmedhamada0/braintumor-detection>, consulté le 03/09/2021.
- [49] <https://www.kaggle.com/sartajbhuvaji/brain-tumor-classification-mri>, consulté le 03/09/2021.
- [50] J. Seetha¹ and S. Selvakumar Raja², Brain Tumor Classification Using Convolutional Neural Networks, 2018.
- [51] Ali pashaei, Hedieh sajadi, Niloofar jazayeri, Brain Tumor Classification Via Convolutional Neural Network and Extreme Learning Machine 2018.
- [52] S. Deepak*, P.M. Ameer, Brain tumor classification using deep CNN features via transfer learning, Computers in Biology and Medicine, 2019, <https://doi.org/10.1016/j.compbiomed.2019.103345>.
- [53] Sarah Ali Abdelaziz Ismael, Ammar Mohammed, Hesham Hefny, An enhanced deep learning approach for brain cancer MRI images classification using residual networks, 2020, <https://doi.org/10.1016/j.artmed.2019.101779>.
- [54] Navid Ghassemia, Afshin Shoeibia, Modjtaba Rouhania, Deep neural network with generative adversarial networks pre-training for brain tumor classification based on MR images, Biomedical Signal Processing and Control, 2019, <https://doi.org/10.1016/j.bspc.2019.101678>.
- [55] Yakub Bhanothu, Anandhanarayanan Kamalakannan and Govindaraj Rajamankam, Detection and Classification of Brain Tumor in MRI Images using Deep Convolutional Network, 2020.

- [56] Francisco Javier Díaz-Pernas, Mario Martínez-Zarzuela , Míriam Antón-Rodríguez and David González-Ortega, A Deep Learning Approach for Brain Tumor Classification and Segmentation Using a Multiscale Convolutional Neural Network, 2021, <https://doi.org/10.3390/healthcare9020153>.
- [57] Alaa Ahmed Abbood, Qahtan Makki Shallal, Mohammed A. Fadhel, Automated brain tumor classification using various deep learning models : a comparative study, DOI : 10.11591.
- [58] Jaeyong Kang, Zahid Ullah and Jeonghwan Gwak, MRI-Based Brain Tumor Classification Using Ensemble of Deep Features and Machine Learning Classifiers, <https://doi.org/10.3390/s21062222>.
- [59] kitchell.github.io/DeepLearningTutorial/7lossfunctionsoptimizers.html, consulté le 03/09/2021.
- [60] Diederik P.Kingma, Jimmy Lei Ba, ADAM : A METHOD FOR STOCHASTIC OPTIMIZATION, Published as a conference paper at ICLR 2015
- [61] <https://deeptai.org/machine-learning-glossary-and-terms/softmax-layer>, consulté le 03/09/2021.
- [62] <https://deeptai.org/machine-learning-glossary-and-terms/early-stopping-machine-learning>, consulté le 03/09/2021.
- [63] https://keras.io/api/callbacks/reduce_lr_on_plateau/,consulté le 03/09/2021.
- [64] <https://nusit.nus.edu.sg/services/hpc-newsletter/deep-learning-best-practices-checkpointing-deep-learning-model-training/>, consulté le 03/09/2021.
- [65] <https://www.pluralsight.com/guides/introduction-to-densenet-with-tensorflow>, consulté le 03/09/2021.
- [66] <https://www.lebigdata.fr/python-langage-definition> ,consulté le 25/02/2021.
- [67] <https://keras.io/>, consulté le 25/02/2021.
- [68] <https://github.com/scikit-learn/scikit-learn> , consulté le 05/06/2021.
- [69] Milica.M, Badža and Marko C Barjaktarovic,Classification of Brain Tumors from MRI Images Using a Convolutional Neural Network, doi :10.3390.
- [70] Ahmet Cinar, Muhammed Yildirim, Detection of tumors on brain MRI images using the hybrid convolutional neural network architecture, doi : <https://doi.org/10.1016/j.mehy.2020.109684>.

[71] <https://www.futura-sciences.com/tech/definitions/intelligence-artificielle-deep-learning-17262/> consulter le 19/11/21.