



DEPARTEMENT DE GENIE ELECTRIQUE

MEMOIRE

DE FIN D'ETUDES POUR L'OBTENTION DU DIPLOME DE MASTER EN

Réseaux Et Télécommunications

THEME

**Conception d'un modèle d'apprentissage profond
pour la détection des maladies cancéreuses**

Présenté par le binôme :

- BEKKAR LATIFA**
- GOUCEM SAFA**

Devant le jury :

- | | | |
|-------------------------------|--------------|------------------|
| - M. AOUICHE ABDELAZIZ | MCA | Président |
| - M. KHEMAISSIA SEDDIK | Pr. A | Encadreur |
| - Mme CHERIET Leila | MCB | Examineur |

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

A decorative floral element with several small flowers and leaves, positioned at the top left of the calligraphic text.

ملخص

يعد اكتشاف أورام المخ في أقرب وقت ممكن أمرًا ضروريًا لبقاء المريض على قيد الحياة. سبب لتطوير تقنية كشف جديدة. يعتبر ورم المخ من الأمراض الخطيرة في المجال الطبي يعمل الأطباء بجد للكشف عن الورم وعلاجه لإنقاذ حياة المرضى. كشف الورم يستغرق الأطباء وقتًا طويلاً ويمكن أن تتغير التشخيصات من طبيب إلى آخر. تقترح هذه الرسالة نموذجين للتعلم العميق لتحديد أورام الدماغ الثنائية (العادية وغير الطبيعية) ومتعددة الطبقات (الورم السحائي، الورم الدبقي والغدة النخامية). لبناء نماذجنا، نطبق أولاً شبكة عصبية تلافيفية (CNN).

ومع ذلك، عند التعامل مع أحجام محدودة من البيانات، كما هو الحال في مجموعة البيانات الثانية، تواجه بنية CNN المقترحة لدينا مشكلة في التخصيص. لحل هذه المشكلة، نستخدم نقل التعلم من InceptionResNet. أخيرًا، قارنا نماذجنا المقترحة مع تلك المذكورة في الأدبيات. تشير نتائجنا التجريبية إلى أن نماذجنا تحقق على التوالي دقة تصنيف تصل إلى 97.8% لمجموعات البيانات الخاصة بنا.

الكلمات المفتاحية: التعلم العميق، CNN، التصوير بالرنين المغناطيسي، الكشف ورم الدماغ الورم السحائي، الورم الدبقي والغدة النخامية.

Résumé

Détecter les tumeurs cérébrales le plus tôt possible est crucial pour la survie d'un patient. Une raison pour développer une nouvelle technique de détection. La tumeur cérébrale est une maladie grave dans le domaine médical. Les médecins travaillent dur pour détecter et traiter la tumeur afin de sauver la vie des patients. Détecter une tumeur prend beaucoup de temps aux médecins et les diagnostics peuvent changer d'un médecin à l'autre. Cette thèse propose deux modèles d'apprentissage profond pour identifier les tumeurs cérébrales bilatérales (normales et anormales) et multicouches (méningiome, gliome et adénome hypophysaire). Pour construire nos modèles, nous appliquons d'abord un réseau de neurones convolutifs (CNN).

Cependant, lorsqu'il s'agit de volumes limités de données, comme dans le cas du deuxième ensemble de données, notre architecture CNN proposée présente un problème d'affectation. Pour résoudre ce problème, nous utilisons l'apprentissage par transfert d'InceptionResNet. Enfin, nous avons comparé nos modèles proposés avec ceux rapportés dans la littérature. Nos résultats expérimentaux indiquent que nos modèles atteignent respectivement une précision de classification allant jusqu'à 97,8 % pour nos ensembles de données.

Mots clés : Tumeur cérébrale, CNN, Deep Learning, IRM, Détection méningiome, gliome et hypophyse.

Abstract

Finding brain tumors as early as possible is Essential for patient survival. Reason why news Automatic detection techniques are developed over time. Brain tumor is a critical disease. Doctors work hard to detect and treat the tumor in order to save the lives of patients. Detection tumor takes a long time for doctors and diagnoses may vary from doctor to doctor. This thesis proposes two deep learning models to identify binary (normal and abnormal) and multiclass (meningioma, glioma and pituitary) brain tumors. To build our models, we first apply a convolutional neural network (CNN).

However, when dealing with limited volumes of data, which is the case in the second dataset, our proposed CNN architecture faces an overfitting problem. To solve this problem, we use InceptionResNet transfer learning. Finally, we compare our proposed models with those reported in the literature. Our experimental results indicate that our models respectively achieve a classification accuracy of up to 97.8% for our datasets.

Keywords: Brain Tumor, CNN, Deep Learning, MRI, Detection meningioma, glioma and pituitary.

REMERCIEMENTS

En premier lieu, nous remercions Allah le Tout-Puissant pour nous avoir donné le potentiel d'apprendre les lois de notre Univers et de les exploiter pour notre bien-être.

Nous remercions énormément **Dr. khemaissia seddik** au département des sciences de la technologie à l'université Echahid Cheikh Larbi Tébessi - Tébessa de nous avoir guidé et soutenu le long de ce travail avec beaucoup de patience et d'indulgence, et nous espérons pouvoir un jour devenir aussi de formidables et maitres à nos futurs élèves.

Nous remercions **Dr. Aouiche Abdelaziz**, au département des sciences de la technologie à l'université Echahid Cheikh Larbi Tébessi - Tébessa de nous avoir fait l'honneur de présider le jury de notre soutenance et également **Dr. Cheriet Leila**, au département des sciences de la technologie à l'université Echahid Cheikh Larbi Tébessi - Tébessa d'avoir accepté d'examiner notre travail.

Un grand merci à toutes les personnes que nous avons consultées pour la compréhension et l'assimilation de ce travail.

Merci à mes amies et collègue pour leurs encouragements.

Et enfin merci et pardon à tous ceux que nous ne pouvons citer qui nous ont aidés de Près ou de loin.

Dédicace

*Louange à Dieu et prières sur l' élu bien-aimé, sa famille
et ceux qui ont accompli sa foi :*

*Louanges et remerciements à Dieu, qui m'a permis de
valoriser cette étape de ma carrière universitaire en
soumettant mon mémoire, que je considère comme le fruit
d'efforts et de labeur pour réaliser le rêve. Et me voilà,
concluant cette année avec mon diplôme avec beaucoup
d'énergie et d'activité, grâce à Dieu Tout-Puissant, et je le
dédie d'abord à moi-même, qui a persévéré, cherché et
fatigué pour réussir, et deuxièmement à mes chers père et
mère, et troisièmement, à mes chers frères, que Dieu
protégez-les, et à tous ceux qui m'ont soutenu dans toutes
les étapes que j'ai traversées, bonnes et mauvaises, et
m'ont encouragé à terminer l'étape académique étape par
étape, et m'accompagnait comme mon imagination pour
S'assurer que je gagnerai le fruit du travail afin de
l'étudier et de le couronner de succès.*



LATIFA. BK

Dédicace

Je dédie mon travail à :

Les deux êtres les plus chers au monde, les bougies qui m'ont toujours dirigée sur le bon chemin : ma mère, la lumière de ma vie, qui a tout fait pour ma réussite et mon bonheur.

Père, puis-je lui donner tout le respect et l'amour pour son soutien et sa tendresse.

*A mes sœurs pour leur aide et leur courage A mes frères
A moi-même A toute la famille et à tous les amis.*



SIFA

Table des matières

Liste des figures	XI
Liste des Tableaux.....	XII
Liste Des Abréviations et Acronymes.....	XIII
Remerciement.....	IV
Dédicace.....	V
Dédicace	VI
Introduction Générale	01
Conclusion Générale	60

Chapitre I : La Tumeur cérébrale et IRM

1. Introduction	05
2. Tumeur cérébrale	05
2.1. Définition	05
2.2. Tumeur cérébrale primaire et tumeur cérébrale métastatique ou secondaire	05
2.3. Tumeurs cérébrales bénignes et tumeurs cérébrales malignes	06
2.3.1. Tumeurs cérébrales bénignes	06
2.3.2. Tumeurs cérébrales malignes	06
3. Types des tumeurs du cerveau	06
3.1. Symptômes de la Tumeur Cérébrale	07
3.2. Classification des Tumeurs Cérébrales	07
3.2.1. Les Gliome.....	08
3.2.2. Glioblastome	08
3.2.3. Méningiome	08
3.2.4. Médulloblastome	08
3.2.5. Adénomes Hypophysaires.....	08
3.2.6. Lymphome cérébral	08
4. Diagnostic d'une tumeur du cerveau	09
5. Imagerie par résonance magnétique (IRM)	09
5.1. Acquisition des images IRM	10

5.2. Principe de Fonctionnement de IRM.....	11
6. Conclusion	12

Chapitre II : Apprentissage Profond

1. Introduction	14
2. Intelligence Artificielle	14
2.1. Apprentissage automatique	14
2.2. Apprentissage en profondeur	15
2.3. Différences entre le machine learning et le deep learning	15
3. Apprentissage en profondeur	15
3.1. Historique	15
3.2. Les réseaux de Neurones Artificiels (ANN)	16
3.3. Les neurones	17
3.4. Neurone biologique	17
4. Couches de perceptron multi layer (MLP)	18
4.1. Comportement de neurones artificiels	20
5. Types de réseaux de neurones	20
5.1. Perceptron à une seule couche (monocouche)	22
5.2. Perceptron Multi Couches	22
5.3. Réseau de neurones récurrents	23
5.4. Réseaux de neurones convolutifs (CNN)	24
6. Conclusion	24

Chapitre III : CNN et Transfer Learning

1. Introduction	26
2. Définition	26
3. Historique	27
4. Architecture de CNN	27
5. Réseaux de neurones convolutionnels (CNN)	28
5.1. Couches convolutives	29
5.2. Couche unité rectifié linéaire (Relu)	31
5.3. Couche Pooling	31

5.4. Couche entièrement connectée	32
5.5. Couche de perte (LOSS)	32
5.6. Algorithme de l'apprentissage en profondeur.....	33
5.6.1. Rétropropagation (Backpropagation).....	34
5.6.2. Époques, itérations et Batch	35
5.7. Architectures des CNN les plus connus	35
6. Transfert Learning	36
6.1. Principe de transfert d'apprentissage.....	36
6.2. Entraînement du modèle	37
6.3. Contourner l'overfitting	38
6.3.1. Data Augmentation	38
6.3.2. Dropout	38
6.3.3. Early Stopping	38
6.3.4. ReduceLROnPlateau	38
6.3.5. Checkpoint	38
7. matrice de confusion	39
8. Mesures utilisant la matrice de confusion et leur signification	40
8.1 Rappel/Sensibilité	40
8.2 Précision	40
8.3 Spécificité	40
8.4 Accuracy	41
8.5 Prévalence	41
8.6 F-Score	41
9. Conclusion	41

Chapitre IV : Implémentation et Résultats

1. Introduction.....	43
2. Configuration du matériel utilisé.....	44
3. Application1 : Classification Binaire	44
3.1. Acquisition de la base de données	44
3.2. Modèles proposes	45
3.2.1. Réseaux de neurones convolutifs (CNN).....	45
3.2.2. ResultatS du modele CNN.....	46
3.2.3. Modèle pré-entraîne : MobileNet	47

3.2.4. Résultats de MobileNet.....	48
4. Application2 : Classification Multi-classe.....	49
4.1. Description du Modèle Inception-ResNet-v2.....	50
4.2. Acquisition de la base de données.....	50
4.3. Importance de la taille du lot (Batch)	51
4.4. Métriques d'évaluation des performances	52
4.5. Résultats obtenus.....	53
4.6. Analyse et Discussion	54
4.7. Comparaison avec d'autres Travaux de la Littérature	56
5. Travaux futurs.....	57
6. Conclusions.....	58

Liste des figures

Figure 1 :	Résumé graphique de la classification d'une tumeur cérébrale.....	03
Figure I.1 :	Tumeurs cérébrales les plus courants	07
Figure I.2 :	Les composants d'IRM	10
Figure I.3 :	Acquisition des images IRM ;(a) : Acquisition pondérée en T1 ; (b) : Acquisition pondérée en T2	11
Figure I.4 :	Les différentes coupes du cerveau	11
Figure I.5 :	Principe général d'un système informatisé d'imagerie	12
Figure II.1 :	différence entre AI, ML et Deep Learning.....	14
Figure II.2 :	Les réseaux de neurones sont composés de plusieurs couches.....	17
Figure II.3 :	Neurone biologique	17
Figure II.4 :	Modèle simplifié d'un réseau de neurones artificiels.....	18
Figure II.5 :	Réseau de neurones artificiels classer un chat.....	19
Figure II.6 :	Architecture du neurone artificiel.....	20
Figure II.7 :	Fonctions d'activation les plus courantes dans les ANN.....	21
Figure II.8 :	Réseau Perceptron	22
Figure II.9 :	Architecture Perceptron Multi couches	23
Figure II.10 :	RNN simple, avec une couche récurrente et une couche dens	23
Figure II.11 :	Réseau de neurones a convolution (CNN)	24
Figure III.1 :	L'architecture d'un CNN.....	28
Figure III.2 :	Un cheval	28
Figure III.3 :	Image convertie en une matrice de valeurs de pixels	29
Figure III.4 :	Exemple des valeurs des matrices et des filtres et pixel des images.....	29
Figure III.5 :	Opération de convolution.....	30
Figure III.6 :	Opération de convolution.....	30
Figure III.7 :	l'image réelle (l'image d'entrée) et l'image convoluée.....	30
Figure III.8 :	l'Unité linéaire rectifiée (Relu)	31
Figure III.9 :	Exemple du Max Pooling.....	32
Figure III.10 :	La couche entièrement connectée	32
Figure III.11 :	les étapes de La couche entièrement connectée	33
Figure III.12 :	Algorithme d'apprentissage.....	33
Figure III.13 :	l'algorithme de rétropropagation.....	34

Figure III.14 :	Traditional Machine Learning vs Transfer Learning	36
Figure III.15 :	Transfer Learning	37
Figure III.16 :	Entraînement par Transfer Learning.....	37
Figure III.17 :	Matrice de confusion... ..	39
Figure IV.1 :	le schéma fonctionnel de la méthode proposée	43
Figure IV.2 :	Image (IRM) du cerveau avec tumeur et sans tumeur	45
Figure IV.3 :	Graphique représentant la précision et la perte de modèle CNN pour l'ensemble d'entraînement et de validation pour 10 epochs	46
Figure IV.4 :	Graphique représentant la précision et la perte de modèle CNN pour l'ensemble d'entraînement et de validation pour 35 epochs	47
Figure IV.5 :	CNN pré-entraînée MobileNet.....	48
Figure IV.6 :	Graphique représentant la précision et la perte de modèle pour l'ensemble d'entraînement et de validation utilisant l'approche MobileNet.....	48
Figure IV.7 :	Architecture globale du Modèle propose.....	49
Figure IV.8 :	Architecture globale de l'Inception-ResNet-v2	50
Figure IV.9 :	type des tumeurs	50
Figure IV.10 :	Graphique représentant la précision et la perte de modèle Inception ResNet v2 pour l'ensemble d'entraînement et de validation pour 20 epochs	52
Figure IV.11 :	comparaison des optimisations Adam et SGD	53
Figure IV.12 :	Matrice de confusion pour 20 epochs et 32 batches	55

Liste des Tableaux

Tableau I.1 :	Caractéristiques des tumeurs malignes et bénignes.....	06
Tableau II.1 :	Les architectures de CNN	35
Tableau IV.1 :	Analyse : évaluation spécifique à la classe d'une tumeur cérébrale.....	54
Tableau IV.2 :	Comparaison de notre modèle avec d'autres travaux de l'état de l'art existants trouvés dans la littérature.....	57

Liste Des Abréviations et Acronymes

AI:	Artificial intelligence
ML:	Machine Learning
DL:	Deep Learning
ANN:	Artificial neural network
MLP:	Multi-Layer Perceptron, MLP : le perceptron multicouche
ReLU:	Linear rectified unit layer
CNN:	Convolutional Neural Network
IRM:	Imagerie par résonance magnétique
RNN:	Recurrent Neural Networks
CONV:	Convolution layer
POOL:	Pooling layer
FC:	Fully connected (les couches entièrement connectées)
TL :	Transfert Learning
OMC :	organisation mondiale de la santé
TC :	tumeur cérébrale

Introduction

Générale

Introduction générale

La recherche médicale vit une révolution numérique liée à l'abondance de données et à notre aptitude à les collecter, à les stocker et surtout à les traiter. Ces possibilités sont liées aux capacités des ordinateurs qui sont aujourd'hui quasi illimitées : ils peuvent analyser des milliards d'informations à une vitesse considérable et comparer une multitude de paramètres, alors que le cerveau humain ne gère guère plus de 6 ou 7 variables en même temps. Associé à l'expertise des médecins, le développement de l'intelligence artificielle (IA) est donc très prometteur en santé.

C'est probablement dans le domaine du diagnostic que l'IA va d'abord bouleverser la cancérologie. Plusieurs équipes de recherche dans le monde ont déjà prouvé que des programmes sont capables de détecter un mélanome, une forme sévère de cancer de la peau, ou un cancer de sein avec plus d'acuité qu'un médecin, même lorsqu'il s'agit d'une tumeur atypique.

L'identification d'une tumeur cérébrale à partir des divers symptômes d'un patient a toujours été une préoccupation majeure pour les professionnels de la santé et les pathologistes lors de la planification d'un diagnostic et d'un traitement.

La majorité des tumeurs constituent une menace pour la vie, y compris les tumeurs cérébrales. Les tumeurs cérébrales peuvent avoir n'importe quelle forme, taille, localisation ou intensité, ce qui rend leur identification et leur diagnostic extrêmement difficiles. Le processus d'identification manuelle des tumeurs à partir des images IRM est spontané et distinct de celui des spécialistes basés sur l'expertise. Actuellement, la détection et le diagnostic reposent principalement sur des neurospécialistes et des radiologues pour l'évaluation des images. Ceci est susceptible d'erreurs humaines et prend également beaucoup de temps.

En raison de la détection tardive des tumeurs, en particulier des tumeurs cérébrales, de nombreux patients décèdent. L'identification et la localisation précoces des cancers cérébraux travaillent sur les possibilités de traitement et de soulagement des patients. Par conséquent, la détection automatisée des tumeurs cérébrales basée sur l'intelligence artificielle contribue à répondre aux principales préoccupations et à produire des résultats supérieurs. Une tumeur cérébrale est une maladie grave avec plus d'un million de cas enregistrés chaque année.

L'apprentissage en profondeur a posé ses racines de manière beaucoup plus décisive dans notre vie quotidienne. En tant que société, nous vivons des changements de style de vie miniatures, tels que les voitures autonomes, Google Assistant, les recommandations Netflix, la détection des spams, et bien d'autres. De même, l'apprentissage profond a également évolué dans le domaine de la santé, où nous utilisons des modèles d'apprentissage profond pour détecter les tumeurs cérébrales à l'aide d'IRM, détecter le covid à l'aide de rayons X pulmonaires, etc.

Une imagerie par résonance magnétique (IRM) est utilisée si une personne a une tumeur au cerveau. Une tumeur au cerveau peut appartenir à n'importe quelle catégorie, et un

Introduction Générale

examen IRM de ces millions de personnes pour décider si une personne souffre ou non de cette maladie, et si oui, quelle est sa catégorie, peut-être une tâche difficile. C'est là que les modèles d'apprentissage en profondeur jouent un rôle vital, où ils peuvent décider si un patient a une tumeur au cerveau ou non simplement en fournissant une image IRM du cerveau du patient à l'aide de réseaux de neurones.

L'objectif principal de ce projet est de construire un modèle d'apprentissage en profondeur avec une grande précision qui peut détecter si une image IRM a une tumeur ou non d'une cote. Ce système peut aider le médecin à prendre des décisions précoces afin que les traitements soient effectués à un stade plus précoce. Nous utiliserons des IRM cérébrales de 3000 patients, dont 1500 images IRM présentent des tumeurs et 1500 autres sont normales.

Une tumeur au cerveau peut appartenir à n'importe quelle catégorie, et un examen IRM de ces millions de personnes pour décider si une personne souffre ou non de cette maladie, et si oui, quelle est sa catégorie, peut-être une tâche difficile. C'est là que les modèles d'apprentissage en profondeur jouent un rôle vital, où ils peuvent décider si un patient a une tumeur au cerveau ou non simplement en fournissant une image IRM du cerveau du patient à l'aide de réseaux de neurones.

D'un autre côté, nous utilisons un ensemble de données de classificateur d'images de tumeurs cérébrales qui contient des images IRM du cerveau humain divisées en ensembles d'entraînement et de test qui sont classées en 4 classes : Gliome , Méningiome, Pituitaire et Pas de tumeur.

L'imagerie par résonance magnétique (IRM) a connu un véritable essor ces dernières années. Cette modalité d'imagerie est devenue un outil de plus en plus important en médecine du cerveau ou dans la recherche en neurosciences cognitives, l'IRM permet une visualisation précise de la formation anatomique des tissus du cerveau. Pour ces raisons, la détection automatique des tumeurs cérébrales devient significative pour éventuellement augmenter la probabilité de survie. Le cancer du cerveau est une maladie critique dans le domaine médical. Les médecins travaillent dur pour détecter et traiter la tumeur afin de sauver la vie des patients. La détection de la tumeur prend beaucoup de temps pour les médecins et les diagnostics peuvent changer d'un médecin à un autre.

Dans ce mémoire, nous proposons un système de classification automatique des tumeurs cérébrales basé sur deux modèles d'apprentissage en profondeur pour identifier les tumeurs cérébrales binaires (normales et anormales) et multiclassées (méningiome, gliome et hypophyse). Pour construire nos modèles, nous appliquons d'abord un réseau de neurones à convolution (CNN). Cependant, lorsqu'il s'agit de volumes limités de données, ce qui est le cas dans le deuxième ensemble de données, notre architecture CNN proposée est confrontée à un problème de surajustement. Pour résoudre ce problème, nous utilisons l'apprentissage par transfert inception ResNET.

Introduction Générale

La figure suivante résume notre système de classification automatique des tumeurs cérébrales basé sur deux modèles d'apprentissage en profondeur.

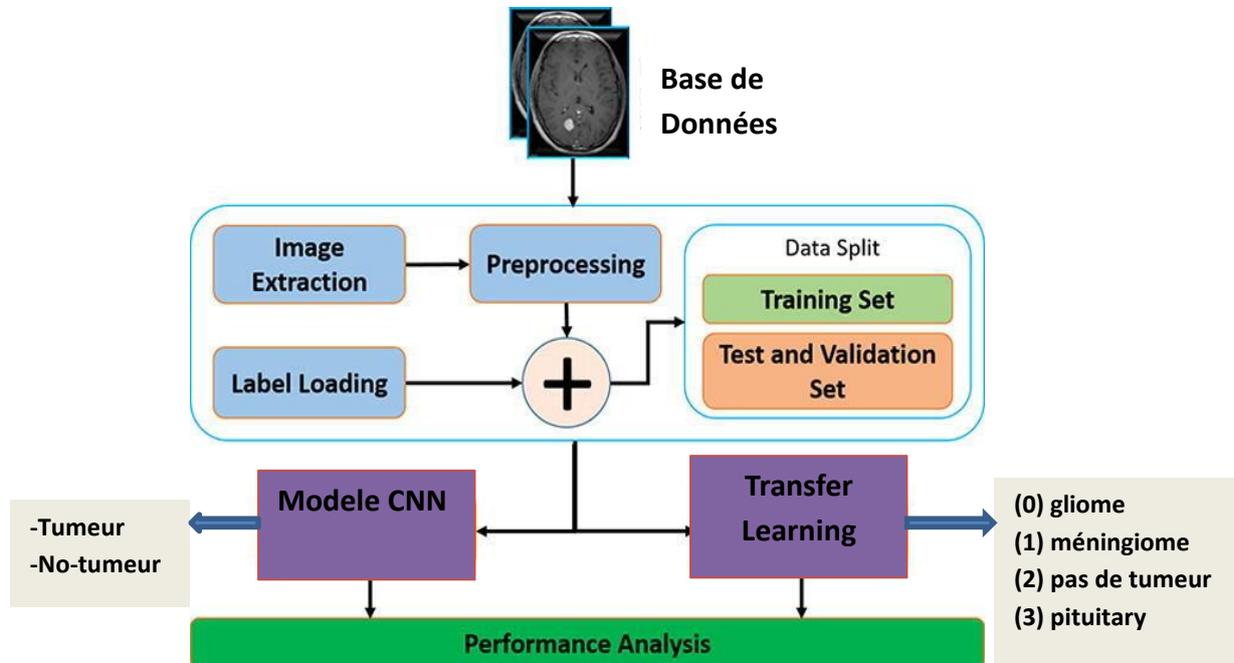


Figure 1 : résumé graphique de la classification d'une tumeur cérébrale.

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 les 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.

Dans le troisième chapitre : Nous détaillons le réseau de neurones convolutifs (CNN) et nous introduisons le concept du Transfer Learning.

Dans le quatrième chapitre : Nous donnons une description du système proposé et nous présentons une discussion des résultats obtenus.

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

Chapitre I

Tumeur Cérébrale

et IRM

1. Introduction

Les tumeurs cérébrales sont un problème de santé important pour tous les groupes d'âge, et les données suggèrent que leur incidence est en augmentation. Chez les nourrissons et les jeunes enfants, les tumeurs du cerveau sont la deuxième forme de cancer la plus courante. Chez les adolescents et les jeunes adultes, les tumeurs cérébrales vont du cinquième au huitième cancer le plus fréquent. Dans la population âgée, l'incidence des tumeurs cérébrales, primitives et métastatiques, est en augmentation. Les tumeurs cérébrales primaires ont une prévalence de 14,7 pour 100 000 aux États-Unis, et il y a environ 80 000 à 100 000 nouvelles tumeurs cérébrales métastatiques chaque année. Ainsi, pratiquement tous les médecins, quelle que soit leur spécialité, rencontreront des patients atteints de tumeurs cérébrales et la plupart des familles auront un parent ou un ami atteint d'une tumeur cérébrale.

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.

2. Tumeur cérébrale

2.1. Définition

Le cerveau peut être le siège de près d'une dizaine de types de tumeurs qui sont classées selon les cellules qui les composent. Une tumeur est toute masse qui résulte d'une multiplication (division) accumulée de cellules anormales. Elle peut également être appelée un néoplasme ou une excroissance (masse).

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.

2.2. Tumeur cérébrale primaire et tumeur cérébrale métastatique ou secondaire

- Les tumeurs cérébrales dites « primaires » sont les cellules qui se développent directement dans une partie des cellules cérébrales et leur enveloppe. Elles peuvent être bénignes ou malignes.
- Les tumeurs cérébrales secondaires (ou métastatiques) sont constituées de cellules provenant d'un autre organe, plus souvent des poumons, des seins, des reins ou de la peau (mélanome). Les tumeurs moins cellulaires de ces organes peuvent migrer vers le cerveau en empruntant le plus souvent la voie sanguine. [1]

2.3. Tumeurs cérébrales bénignes et tumeurs cérébrales malignes

Les tumeurs ne sont pas nécessairement des tumeurs cancéreuses, elles peuvent être existe 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

2.3.1. Tumeurs cérébrales bénignes

Les tumeurs cérébrales bénignes sont constituées de cellules qui croissent lentement. Bien qu'elles n'envahissent pas les tissus avoisinants, elles peuvent être à l'origine des symptômes importants si elles exercent une pression sur des zones sensibles du cerveau. Si une tumeur bénigne interfère avec des fonctions vitales (parole, mobilité, etc.), ses effets peuvent être aussi dangereux que ceux d'une tumeur maligne. [2]

2.3.2. Tumeurs cérébrales malignes

Les tumeurs cérébrales malignes contiennent des cellules qui se multiplient rapidement, leurs contours ne sont pas bien définis, elles croissent rapidement et peuvent envahir et endommager des structures cérébrales importantes. Toutes les lésions cérébrales métastatiques sont considérées comme malignes. Le tableau I.1 compare les caractéristiques des tumeurs malignes et bénignes [2].

Tumeur bénigne	Tumeur maligne
Bien limitée	Mal limitée
Encapsulée, exerce simple	Non encapsulée
Bien différenciée	Différenciation variable
Cellules régulières	Cellules irrégulières
Croissance lente	Croissance rapide
Refoule sans destruction le tissu normal	Envahit et détruit le tissu normal
Pas de récurrence locale	Récurrence possible
Pas de métastase	Métastase

Tableau I.1 : caractéristiques des tumeurs malignes et bénignes

3. Types des tumeurs du cerveau

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.

Il existe un grand nombre de tumeurs du cerveau différentes. Selon leur localisation, leur taille et la vitesse à laquelle elles se développent, ces tumeurs n'entraînent pas les mêmes

symptômes et n'ont pas la même gravité. Les tumeurs du cerveau portent généralement le nom des cellules à partir desquelles elles se développent.

3.1. Symptômes de la Tumeur Cérébrale

Les Symptômes d'une Tumeur Cérébrale se diffèrent selon le volume, la vitesse de propagation et la localisation de tumeur. Les symptômes les plus fréquents sont :

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

3.2. Classification des Tumeurs Cérébrales

La classification officielle des tumeurs cérébrales, proposée par l'organisation mondiale de la santé (OMS), s'effectue selon des critères d'origine cellulaire et leur degré de malignité. [1]

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 :

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

Parmi les TC primitives les plus fréquents on trouve :

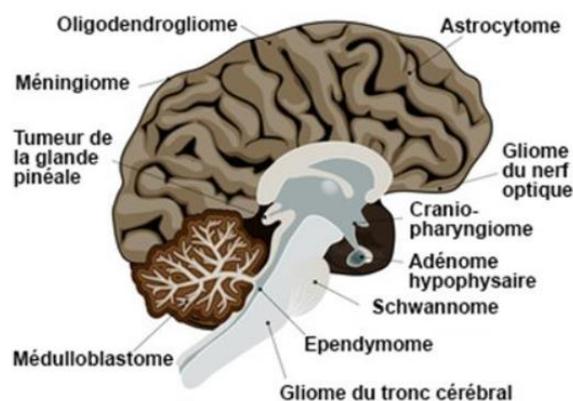


Figure I.1 : tumeurs cérébrales les plus courantes. [3]

3.2.1. Les Gliome

Ces sont les cancers les plus connus, appelés comme ainsi parce que la cellule endommagée est la cellule gliale qui se trouve autour des neurones. La classification prend en compte le degré d'agressivité. Il y a plusieurs types, de I à IV, le premier étant le moins agressif. [4]

3.2.2. Glioblastome

Il s'agit du grade IV des gliomes, il est le plus agressif et le plus répandu. Les traitements connus aujourd'hui ne permettent pas de guérir cette maladie. Il n'a que des moyens par chimiothérapie et radiothérapie de rallonger l'espérance de vie à un an, un an et demi. [4]

3.2.3. Méningiome

Le méningiome affecte les cellules des méninges et peut être localisé autour du cerveau et de la moelle épinière. La forme la plus courante de méningiome est bénigne, et son pronostic favorable [3]

3.2.4. Médulloblastome

C'est une lésion maligne au niveau de la moelle épinière et du cervelet. Cette lésion tumorale apparaît principalement chez les enfants et les adolescents. Cela provoque comme symptôme des troubles de la marche, de l'équilibre, une hypertension intracrânienne. Il y a des traitements spécifiques et la possibilité de guérir selon le stade d'intervention. [4]

3.2.5. Adénomes Hypophysaires

C'est une tumeur le plus souvent bénigne qui se développe dans la glande de l'hypophyse. Cette glande, située derrière le chiasma optique, dans la fosse hypophysaire de l'os sphénoïde, contient des cellules qui produisent des hormones réglant l'activité de plusieurs organes. Un adénome hypophysaire peut alors créer des déséquilibres hormonaux. En fonction de l'adénome le traitement sera médical ou chirurgical. Les adénomes hypophysaires sont pour la majeure partie des lésions bénignes. Si elles sont malignes, le pronostic est favorable si elles sont traitées à temps détaille le médecin. [4]

3.2.6. Lymphome cérébral

Le lymphome cérébral touche en particulier les patients immunodéficients et les personnes âgées de plus de 60 ans. Son traitement n'est pas pratiqué partout, car il nécessite une surveillance étroite, une chimiothérapie lourde. Une partie des patients peuvent avoir une rémission très longue et il y a beaucoup de récives. Les spécialistes étudient des traitements avancés à partir de cellule souches afin d'améliorer le pronostic, qui est pour le moment encore défavorable. La survie est plus importante chez les jeunes. [4]

4. Diagnostic d'une tumeur du cerveau

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.

Pour établir le diagnostic de métastases cérébrales, on a recours à des techniques d'imagerie médicale permettant de bien visualiser les structures cérébrales. Dans la grande majorité des cas, on réalise :

- Une imagerie par résonance magnétique ou l'IRM du cerveau : c'est l'examen le plus fréquent pour diagnostiquer des métastases cérébrales. Cette technique utilisant des produits de contraste est utile pour rechercher des anomalies, qui sont moins visibles avec d'autres techniques d'imagerie médicale, et de mieux caractériser la tumeur ou les métastases.
- Un scanner du cerveau : c'est un examen proche de l'IRM qui permet grâce aux rayons X d'obtenir des vues du cerveau en coupe, de délimiter avec précision la localisation, la taille et l'extension ou les contours des métastases ainsi que ses répercussions sur le cerveau. [5]

5. Imagerie par résonance magnétique (IRM)

L'imagerie par résonance magnétique nucléaire (IRM) est une technique d'imagerie médicale d'apparition récente, non invasive et sans effets secondaires permettant d'avoir une vue 2D ou 3D d'une partie du corps, notamment du cerveau. Elle est basée sur le phénomène physique de résonance magnétique nucléaire. Il s'agit simplement d'observer la résonance magnétique nucléaire (RMN) des protons de l'eau contenus dans l'organisme. Le principe consiste à mesurer l'aimantation des tissus biologiques et à reconstruire une image à partir de ces aimantations. Cette dernière est induite par l'hydrogène, qui s'y trouve en abondance dans le corps humain.

Le patient placé dans un puissant champ magnétique, tous les atomes d'hydrogène s'orientent dans la même direction : ils sont alors excités par des ondes radio durant une très courte période. À l'arrêt de cette stimulation, les atomes restituent l'énergie accumulée en produisant un signal qui est enregistré et traité sous forme d'image par un système informatique.

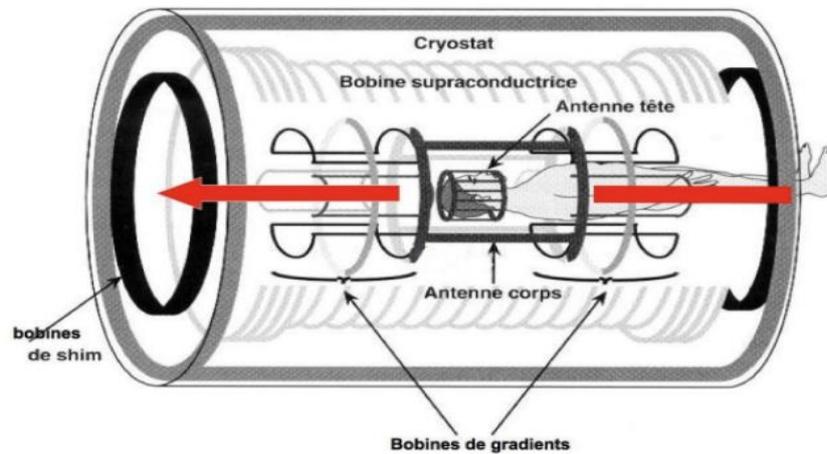


Figure 1.2 : Les composants d'IRM . [6]

Après arrêt de la stimulation, les atomes d'hydrogène restituent cette énergie qui se dissipe dans différents plans de l'espace sous l'action du champ magnétique de l'aimant. L'énergie est alors captée par d'autres antennes (antennes réceptrices) puis analysée par un ordinateur. Suivant la composante en eau des tissus analysés, leurs pathologies éventuelles, les images seront différentes et l'ordinateur réalise des images en noir et blanc d'une très grande sensibilité et très précieuses pour le diagnostic, notamment en matière de pathologie tumorale ou infectieuse. Il est ainsi possible de réaliser des coupes de n'importe quelle partie du corps, dans tous les plans de l'espace. [1]

5.1. Acquisition des images IRM

L'IRM permet d'obtenir des images numériques en trois dimensions d'une précision inférieure au millimètre, du cortex, de la substance blanche, du liquide céphalo-rachidien et des noyaux gris centraux. Deux paramètres réglables cliniquement entrent en jeu lors de l'acquisition : le temps de répétition des séquences d'impulsion (TR), et le temps d'écho (TE). Une acquisition effectuée avec des temps TR et TE courts est dite en T1 (**Figure I.3.a**). Lorsque ces deux temps sont longs, elle est dite en T2 (**Figure I.3.b**). Enfin lorsque TR est long et TE est court, elle est dite en rho ou densité de proton. Toute l'acquisition peut être caractérisée par rapport à ces trois types particuliers. Ainsi, on parle d'image pondérée en T1 si l'acquisition se rapproche plus de type d'acquisition en T1 que des deux autres types : de façon similaire, on parle d'acquisition pondérée en T2 ou en ρ . De plus, on peut renforcer le signal de certaines structures sur les séquences pondérées en T1 grâce à l'utilisation d'un agent de contraste tel que le gadolinium. [1]

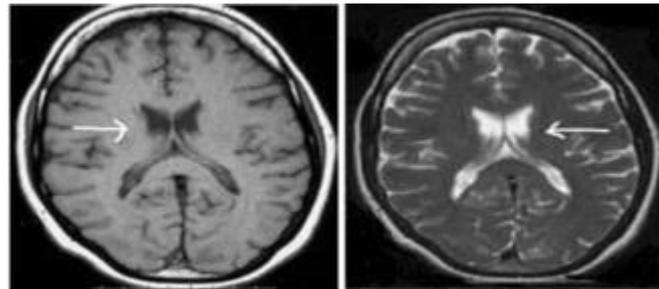


Figure I.3 : Acquisition des images IRM ; (a) : Acquisition pondérée en T1 ; (b) : Acquisition pondérée en T2. [7]

Au niveau cérébral, l'IRM permet également d'étudier les artères du cou et du cerveau (figure I.4).

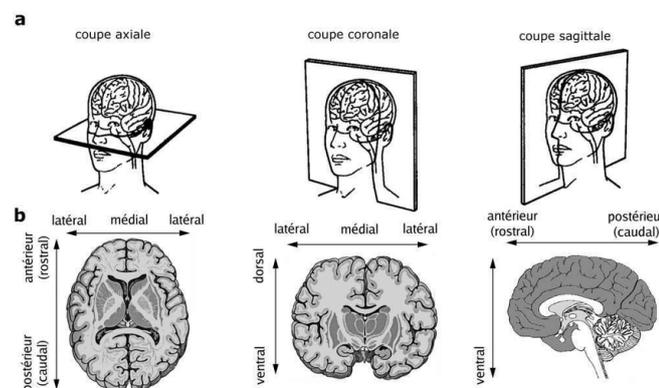


Figure I.4 : Les différentes coupes du cerveau. [8]

5.2. Principe de Fonctionnement d'IRM

L'imagerie par résonance magnétique (IRM) utilise un aimant très puissant qui fait « vibrer » les atomes d'hydrogène, éléments qui composent les molécules d'eau de notre corps. Notre organisme est constitué de plus de 65 % d'eau. Au centre de chaque atome d'hydrogène se trouve une particule encore plus petite appelée proton : c'est cette particule qui est à l'origine du phénomène. Une antenne placée autour de la région à examiner va capter les « vibrations » des protons, les protons « vibrent » à des vitesses variables, selon le type de tissu dans lequel ils se trouvent. Cela permet de bien distinguer les différentes structures de l'organisme sur les images obtenues, dont les tumeurs par exemple. L'injection d'un produit de contraste est souvent nécessaire pendant l'examen afin de mieux visualiser la zone à examiner. [9]

Les signaux reçus des millions de protons dans le corps sont réunis pour créer des images en coupes détaillées de l'intérieur du corps. Des images en 2 ou 3 dimensions sont ensuite reconstituées par un ordinateur avant d'être interprétées par un radiologue. [9]

La figure ci-dessous (**Figure I.5**) nous montre le processus général d'acquisition d'images.

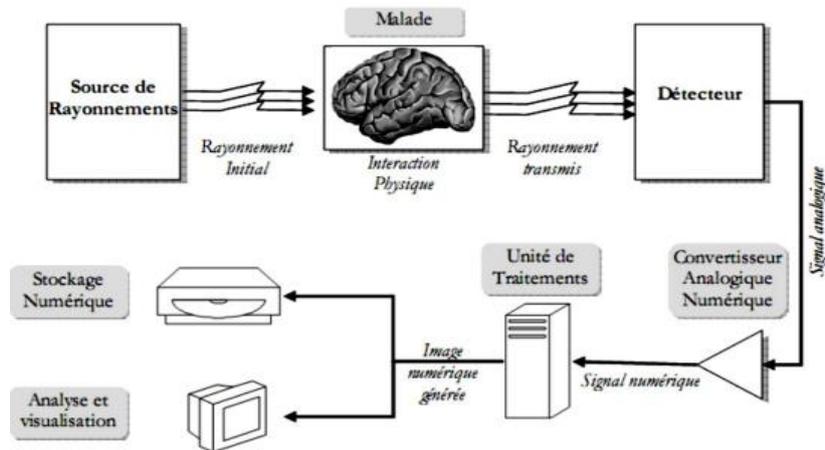


Figure I.5 : Principe général d'un système informatisé d'imagerie. [10]

6. Conclusion

Dans ce chapitre, nous avons abordé de manière générale les différentes notions de bases relatives à la tumeur, puis nous avons présentée 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.

Finalement, nous avons montré le diagnostic des tumeurs cérébrale à partir d'imagerie par résonance magnétique.

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

Chapitre II

L'apprentissage

profond

(Deep learning)

Chapitre II L'apprentissage Profond (Deep Learning)

1. Introduction

Intelligence artificielle et apprentissage profond sont devenus les technologies dont on parle le plus dans le monde commercial d'aujourd'hui, car les entreprises utilisent ces innovations pour créer des machines et des applications intelligentes. Et bien que ces termes dominent les dialogues commerciaux partout dans le monde, de nombreuses personnes ont du mal à les différencier.

Les trois termes sont souvent utilisés de manière interchangeable, mais ils ne désignent pas tout à fait les mêmes choses. Dans ce qui suit nous allons indiquer les différences fondamentales entre l'intelligence artificielle, l'apprentissage automatique et l'apprentissage profond.

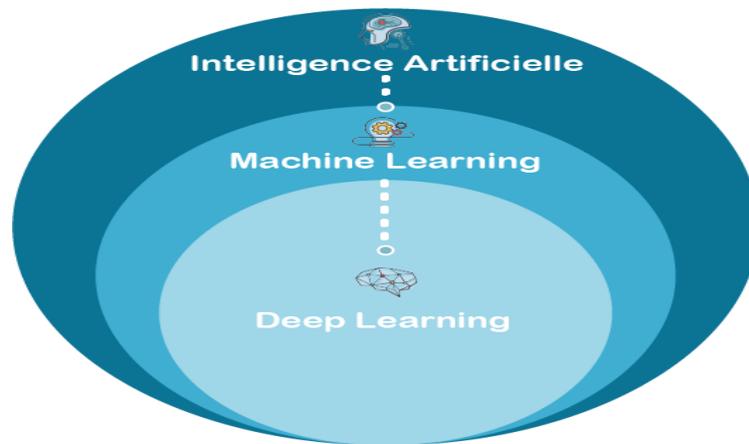


Figure II.1 : différence entre AI, ML et Deep Learning.

2. Intelligence Artificielle

L'intelligence artificielle est née dans les années 1950 et était une discipline universitaire créée en 1956. L'intelligence artificielle est «le groupe de théories et de techniques appliquées pour produire des machines capables de simuler l'intelligence humaine», et donc la capacité d'un ordinateur ou un robot contrôlé par un ordinateur pour effectuer des tâches, généralement parce qu'il nécessite de l'intelligence et de l'excellence. Bien que l'intelligence artificielle ne puisse pas effectuer la variété de tâches qu'un humain normal peut effectuer, certains systèmes d'IA peuvent simuler des humains dans des tâches spécifiques. [11]

2.1. Apprentissage automatique

Un apprentissage automatique (Machine learning en anglais ML) est un sous-ensemble de l'intelligence artificielle. Où à Travers elle l'étude des algorithmes informatiques qui s'améliorent automatiquement par l'expérience et entraînent ainsi l'ordinateur à accomplir des tâches qui peuvent être impossibles pour une personne. Lorsque l'appareil a fini d'analyser les données et apprend de ces données, il peut prédire la valeur ou la catégorie de le nouveau point de données et devient ainsi capable de prendre des décisions avec une intervention humaine minimale. De plus, Arthur Samuel a défini l'apprentissage automatique comme «un

Chapitre II L'apprentissage Profond (Deep Learning)

domaine d'étude qui donne aux ordinateurs la capacité d'apprendre sans être explicitement programmés». [11]

2.2. Apprentissage en profondeur

L'apprentissage profond est l'incarnation de l'idée de représentations en cascade où l'apprentissage profond s'entraîne sur d'énormes ensembles de données. Parce qu'il y a de nombreux paramètres qu'un algorithme d'apprentissage doit comprendre. Il contient des dizaines, voire des centaines de couches successives de représentations. Il traite de nombreux réseaux de neurones, dont le plus important est le réseau de neurones artificiels, et constitue donc un sous-ensemble et un complément d'algorithmes d'apprentissage automatique. Ces technologies ont permis des avancées significatives et rapides dans les domaines de l'analyse des signaux audio ou visuels, en particulier la reconnaissance vocale, la reconnaissance faciale, le traitement du langage machine et la vision par ordinateur. Dans les années 2000, ces progrès ont stimulé d'importants investissements privés, universitaires et publics, notamment de la part du GAFAM (Google, Apple, Face book, Amazon et Microsoft). [11]

2.3. Différences entre le machine Learning et le Deep Learning

Ci-dessous, nous avons répertorié certaines des principales différences entre l'apprentissage automatique et l'apprentissage en profondeur :

- **Base de données** : le Machine Learning utilise des milliers de bases de données, tandis que le Deep Learning plus complexe utilise des millions de points de données.
- **Sortie** : les sorties d'apprentissage automatique incluent des valeurs numériques telles que des scores et des classifications. L'apprentissage en profondeur peut produire les mêmes valeurs numériques plus des éléments de forme libre tels que du texte et du son.
- **Algorithmes** : en machine Learning, des algorithmes automatisés utilisent modèle fonctions et faire des prédictions basées sur des données. L'apprentissage en profondeur utilise l'ANN pour transmettre des données à travers plusieurs couches afin d'interpréter les caractéristiques et les relations des données. [12]

3. Apprentissage Profond

3.1. Historique

L'idée du Deep Learning n'est pas une idée récente, mais elle date en réalité des années 1980, la première fois que l'on parle de Deep Learning, c'est grâce à la professeure Rina Dechter en 1986. Ensuite, cette approche est mise en pratique par Yann LeCun en 1989. L'actuel boss de l'IA chez Facebook avait à l'époque utilisé un réseau de neurones artificiel profond afin de reconnaître les codes postaux écrits à la main sur des lettres. Un programme simple aujourd'hui, mais qui avait nécessité trois jours d'apprentissage à l'époque.

Chapitre II L'apprentissage Profond (Deep Learning)

En collaboration Yann LeCun avec deux autres informaticiens, Kunihiro Fukushima et Geoffrey Hinton, ils mettent au point un type d'algorithme particulier appelé Convolutional neural network.

C'est dans ce contexte qu'en 2007 le STANFORD VISION LAB, avec Fei-Fei Li à sa tête, développent un agrégateur d'images où sont consignés et étiquetés quelques millions de photos : ImageNet. En 2010, ImageNet regroupe 15 000 000 d'images toutes catégorisées en fonction de leurs caractéristiques propres (véhicules, animaux, ...).

Des recherches et des études sur la structure des réseaux de neurones continueront d'animer la communauté scientifique jusqu'en 2009, année où cette pratique prend son envol. On considère cette année comme le big bang du DL. À ce moment-là, Nvidia met ses processeurs graphiques (GPU) à contribution. Pour Andrew Ng, cofondateur de Google Brain, l'exploitation des GPU pourrait créer des systèmes d'apprentissage profond jusqu'à 100 fois plus rapides. L'entraînement des algorithmes passerait de plusieurs semaines à seulement quelques jours.

C'est ainsi que Andrew Ng crée une architecture avec bien plus de couches et de neurones qu'auparavant. Il l'entraîne ensuite avec des contenus provenant de 10 millions de vidéos YouTube afin que son programme puisse identifier et extraire les images avec des chats. Nous sommes en 2012.[13][14]

3.2. Réseaux de Neurones Artificiels

Un réseau neuronal est une sorte de logiciel cérébral ou de machine virtuelle composée de milliers d'unités (les neurones) qui effectuent des calculs. Plus précisément, des unités logiques et de prises de décisions (neurones, perceptrons) relient les données d'entrées et de sorties entre elles par l'intermédiaire d'un réseau complexe (réseau, cerveau) capable de prendre des décisions complexes. [15]

A l'origine, ces systèmes portaient le nom de réseaux artificiels de neurones (ANN, Artificiel Neural Networks) afin de les différencier des systèmes biologiques. Ils se composent en général d'un certain nombre de données d'entrées et de sorties (input / output layer), d'un réseau étroit de neurones et de plusieurs couches intermédiaires (hidden layers). Ces couches intermédiaires permettent de traiter des problèmes complexes ; sans elles, le système ne résout que des calculs simples. Le nombre de couches est donc un facteur décisif pour la complexité du système, et de l'apprentissage ; les données se joignent d'une couche à l'autre, les résultats d'une première couche servant d'entrée à la prochaine, et ainsi de suite afin d'aboutir à une prise de décision complexe. Ce fonctionnement en couches donne toute sa profondeur au réseau et à l'apprentissage. L'adjectif « profond » s'entend ici dans tous les sens du terme.

L'exemple ci-dessus présente des unités d'entrées, des sortie et deux couches intermédiaires (couches cachées). Vous constatez que les neurones sont « fortement interconnectés », ce qui constitue une propriété essentielle des réseaux de neurones. C'est

Chapitre II L'apprentissage Profond (Deep Learning)

justement ce qui autorise les relations, fonctions ou décisions d'être complexes ; sans cette propriété, les relations entrée-sortie seraient relativement simples.

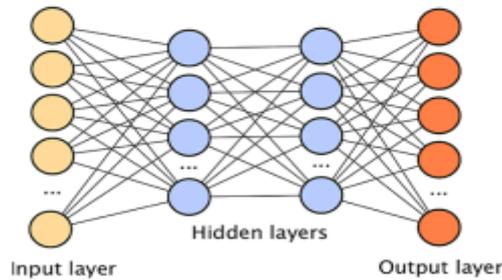


Figure II.2 : Les réseaux de neurones sont composés de plusieurs couches

L'objectif n'est pas de créer un modèle exact du cerveau, mais bien de reproduire sa capacité d'apprentissage et de reconnaissance de connexions complexes. Un être humain peut avoir jusqu'à 100 milliards de neurones qui fonctionnent à une fréquence d'environ 1 kHz ; un processeur moderne fonctionne avec 2 milliards de transistors à 3 GHz.[15]

3.3. Les neurones

Les réseaux de neurones artificiels constituent l'une des approches IA dont le développement se fait à travers les méthodes par lesquelles l'homme essaye toujours d'imiter la nature et de reproduire des modes de raisonnement et de comportement qui lui sont propre. Nous présentons dans cette section de chapitre un état de l'art de ces réseaux de neurones.

3.4. Neurone biologique

Le neurone biologique (voir **figure II.3**) est une cellule nerveuse qui constitue l'unité fonctionnelle fondamentale du système nerveux de tous les animaux. Les neurones existent pour communiquer les uns avec les autres et transmettre des impulsions électrochimiques à travers les synapses, d'une cellule à l'autre, à condition que l'impulsion soit suffisamment puissante pour activer la libération de produits chimiques à travers une fente synaptique. La force de l'impulsion doit dépasser un seuil minimal, sinon les produits chimiques ne seront pas libérés.

La figure présente les principales parties de la cellule nerveuse : le soma, les dendrites, les axones et les synapses.

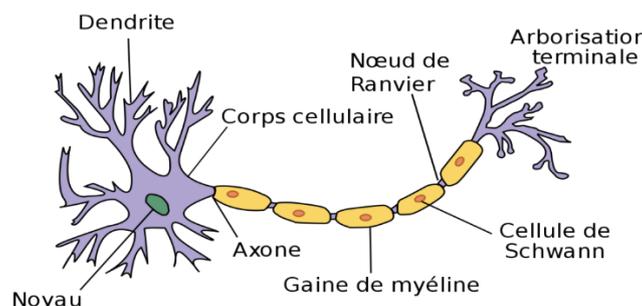


Figure II.3: Neurone biologique. [16]

Chapitre II L'apprentissage Profond (Deep Learning)

4. Couches de Perceptron Multi layer (MLP)

Au sein d'un processeur, l'unité logique se compose de transistors ; on pourrait également y trouver un réseau neuronal « câblé », mais il faudrait qu'il soit « adaptatif », qu'il ait une « capacité d'apprentissage ». En effet, la réponse d'un neurone à des impulsions entrantes doit pouvoir évoluer tout au long du processus d'apprentissage. C'est ce qu'on appelle la « pondération » : un neurone évalue (pondère) diverses variables d'entrée pour obtenir la variable de sortie souhaitée. C'est pourquoi les neurones sont généralement des fonctions mathématiques qui relient entre elles des variables d'entrée et de sortie.

Dans la phase d'apprentissage, les neurones modifient leur comportement de pondération et affinent les résultats de sortie en fonction des variables d'entrée. Il doit donc y avoir un retour d'information du résultat global qui influence chaque neurone. On peut donc dire que les variables d'entrée et de sortie d'un réseau neuronal sont connues, mais que les valeurs des neurones, surtout dans les couches cachées restent inconnues.

Pris isolément, un réseau neuronal qui n'a pas été entraîné ne « connaît » rien et fournit des résultats aléatoires, voire chaotiques pour l'utilisateur. Seul un système entraîné fournira le résultat souhaité. Si le problème posé est simple, un programme simple, plus facile à déboguer, pourra le résoudre. Pour un problème plus complexe, on aura recours à un réseau de neurones, que l'on entraînera à l'aide de grands ensembles de données. Chaque neurone peut fournir des variables de sortie complexes et réagir linéairement ou non linéairement aux variables d'entrée. C'est là un point assez subtil, car les neurones doivent être en mesure de réagir à l'ensemble des possibilités afin de fournir un résultat adéquat. Ceci implique deux choses : soit le programmeur du réseau neuronal connaît toutes les connexions possibles internes au réseau, soit il conçoit le réseau de manière si complexe qu'il couvre « toutes » les possibilités. [17]

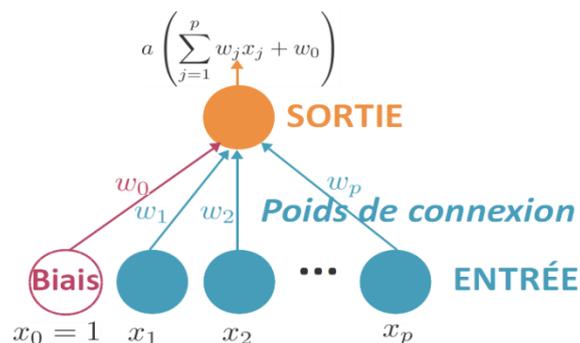


Figure II.4: Modèle simplifié d'un réseau de neurones artificiels. [18]

Pour comprendre comment fonctionne les réseaux de neurones, prenons un exemple concret de reconnaissance d'images. Imaginons que le réseau de neurones soit utilisé pour reconnaître les photos qui comportent au moins un chat. Pour pouvoir identifier les chats sur les photos, l'algorithme doit être en mesure de distinguer les différents types de chats, et de reconnaître un chat de manière précise quel que soit l'angle sous lequel il est photographié.

Chapitre II L'apprentissage Profond (Deep Learning)

Afin d'y parvenir, le réseau de neurones doit être entraîné. Pour ce faire, il est nécessaire de compiler un ensemble d'images d'entraînement pour pratiquer le DL. Cet ensemble va regrouper des milliers de photos de chats différents, mélangés avec des images d'objets qui ne sont pas des chats. Ces images sont ensuite converties en données et transférées sur le réseau. Les ANN assignent ensuite un poids aux différents éléments. La couche finale de neurones va alors rassembler les différentes informations pour déduire s'il s'agit ou non d'un chat.

Pour comprendre comment fonctionne les réseaux de neurones, prenons un exemple concret de reconnaissance d'images. Imaginons que le réseau de neurones soit utilisé pour reconnaître les photos qui comportent au moins un chat. Pour pouvoir identifier les chats sur les photos, l'algorithme doit être en mesure de distinguer les différents types de chats, et de reconnaître un chat de manière précise quel que soit l'angle sous lequel il est photographié.

Afin d'y parvenir, le réseau de neurones doit être entraîné. Pour ce faire, il est nécessaire de compiler un ensemble d'images d'entraînement pour pratiquer le DL. Cet ensemble va regrouper des milliers de photos de chats différents, mélangés avec des images d'objets qui ne sont pas des chats. Ces images sont ensuite converties en données et transférées sur le réseau. Les ANN assignent ensuite un poids aux différents éléments. La couche finale de neurones va alors rassembler les différentes informations pour déduire s'il s'agit ou non d'un chat.

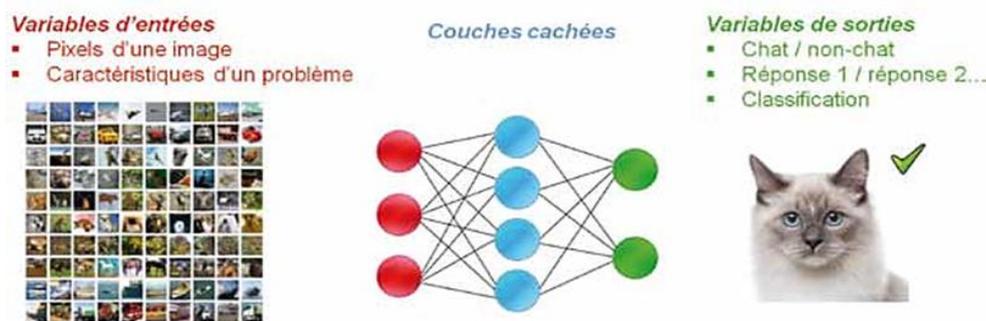


Figure II.5 : Réseau de neurones artificiels classer un chat.

Le réseau de neurones va ensuite comparer cette réponse aux bonnes réponses indiquées par les humains. Si les réponses correspondent, le réseau garde cette réussite en mémoire et s'en servira plus tard pour reconnaître les chats. Dans le cas contraire, le réseau prend note de son erreur et ajuste le poids placé sur les différents neurones pour corriger son erreur. Le processus est répété des milliers de fois jusqu'à ce que le réseau soit capable de reconnaître un chat sur une photo dans toutes les circonstances. [14][19]

Chapitre II L'apprentissage Profond (Deep Learning)

4.1. Comportement de neurones artificiels

Par analogie avec la biologie, ANN (**figure II.6**), reçoit l'information provenant des entrées $x(i = 1, 2, 3 \dots n)$ par l'intermédiaire des connexions dont on affecte à chacune d'elles un poids w_i abréviation de Wight en anglais pondérant l'information, et aussi représentatif de la force de la connexion. Le neurone artificiel fonctionne en deux étapes :

La première phase représente les prétraitements des données reçus en calculant le potentiel v_j des neurones j par la fonction suivante

:

$$v_j = b_j + \sum_{i=0}^n w_{i,j} x_i \quad (II.1)$$

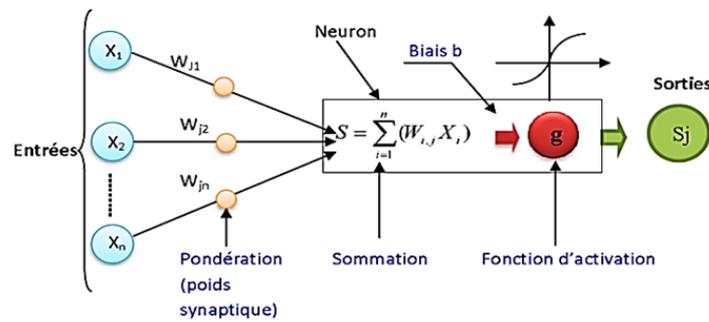


Figure II.6 : Architecture du neurone artificiel.

Où

$w_{i,j}$: désigne le poids de la connexion liant le neurone j à l'entrée i ;

b_j : terme constant appelé biais, il est considéré comme le poids d'une entrée 0 x égal à 1.

Ainsi la relation s'écrit plus simplement :

$$v_j = \sum_{i=0}^n w_{i,j} x_i \quad (II.2)$$

Dans la deuxième phase, une fonction de transfert g appelée également fonction d'activation, calcule la valeur de l'état interne s_j du neurone j à partir de la valeur du potentiel v_j . Cette valeur désignera la sortie du neurone :

$$s_j = g(v_j) = g(\sum_{i=0}^n w_{i,j} x_i) \quad (II.3)$$

Le choix de la fonction d'activation se révèle dans certains cas être un élément constitutif important des réseaux de neurones. Ainsi, le neurone peut être défini mathématiquement comme étant une fonction algébrique, non linéaire (suivant g) et bornée, des entrées x_i et paramétrée par les poids $w_{i,j}$:

Chapitre II L'apprentissage Profond (Deep Learning)

$$S_j = g(x_i, w_{j,i}) = g_{w_{j,i}}(x_i) \quad i = (1, 2, 3 \dots n) \quad (\text{II.4})$$

La fonction d'activation est un élément essentiel aux réseaux de neurones. Elle introduit une non-linéarité dans le modèle et permet d'étendre la dimension de l'espace des hypothèses. Sans cette fonction d'activation, le modèle pourrait seulement apprendre des transformations linéaires ce qui restreindrait trop l'espace des hypothèses.[21][20]

Les fonctions d'activation les plus courantes sont :

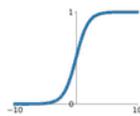
- **La fonction ReLU (Rectified Linear Activation)**
- **La fonction sigmoïde**

La fonction ReLU (**figure II.8**) permet d'éviter les valeurs négatives à la sortie du neurone puisqu'elle met à zéro toutes les valeurs négatives alors que les valeurs positives sont inchangées. C'est une des fonctions d'activation les plus utilisées dans les réseaux de neurones. La fonction sigmoïde (**figure II.7**) retourne une valeur comprise entre 0 et 1. C'est une fonction d'activation souvent utilisée pour la dernière couche afin d'obtenir à la sortie du réseau un score qui peut s'interpréter comme une probabilité.[22]

Activation Functions

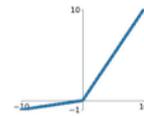
Sigmoid

$$\sigma(x) = \frac{1}{1+e^{-x}}$$



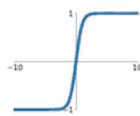
Leaky ReLU

$$\max(0.1x, x)$$



tanh

$$\tanh(x)$$

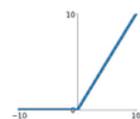


Maxout

$$\max(w_1^T x + b_1, w_2^T x + b_2)$$

ReLU

$$\max(0, x)$$



ELU

$$\begin{cases} x & x \geq 0 \\ \alpha(e^x - 1) & x < 0 \end{cases}$$

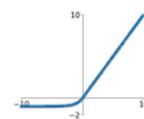


Figure II.7 : Fonctions d'activation les plus courantes dans les ANN. [23]

5. Types de réseaux de neurones

Il existe plusieurs types d'ANN, chaque type étant développé pour des applications particulières.

Chapitre II L'apprentissage Profond (Deep Learning)

5.1. Perceptron à une seule couche (monocouche)

La forme la plus simple d'un réseau de neurone est le perceptron. Ce réseau est considéré parmi les premiers réseaux de neurones. Il a été inventé en 1957 par Rosenblatt.

Le perceptron se compose d'un neurone artificiel à poids ajustable et d'un seuil. Il n'a qu'une seule sortie à laquelle toutes les entrées sont connectées.

Dans ce type de réseaux, seulement les poids entre les unités d'entrées et la sortie peuvent être modifiés, tandis que la sortie de neurone ne peut prendre que deux états : -1 et 1 ou 0 et 1.

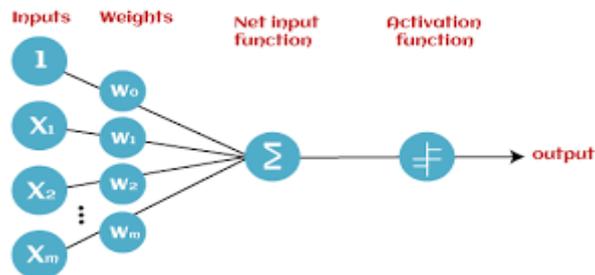


Figure II.8 : Réseau Perceptron.

5.2. Perceptron Multi Couches

Le perceptron Multi Couches PMC ou MLP (Multi Layer Perceptron) en anglais est une extension du perceptron monocouche, avec une ou plusieurs couches cachées entre l'entrée et la sortie.

L'idée principale est de grouper des neurones dans une couche. En place ensuite bout à bout plusieurs couches et on connecte complètement les neurones de deux couches adjacentes (**Figure II.9**). Les entrées des neurones de la deuxième couche sont donc en fait les sorties des neurones de la première couche. Les neurones de la première couche sont reliés au monde extérieur et reçoivent tous le même vecteur d'entrée. Ils calculent alors leurs sorties qui sont transmises aux neurones de la deuxième couche, etc. Les sorties des neurones de la dernière couche forment la sortie du réseau. Les réseaux multicouches sont beaucoup plus puissants que les réseaux simples à une seule couche. En utilisant deux couches (une couche cachée et une couche de sortie) à condition d'employer une fonction d'activation sigmoïde sur la couche cachée, on peut entraîner un réseau à produire une approximation de la plupart des fonctions, avec une précision arbitraire (cela peut cependant requérir un grand nombre de neurones sur la couche cachée). Sauf dans de rares cas, les réseaux de neurones artificiels exploitent deux ou trois couches.

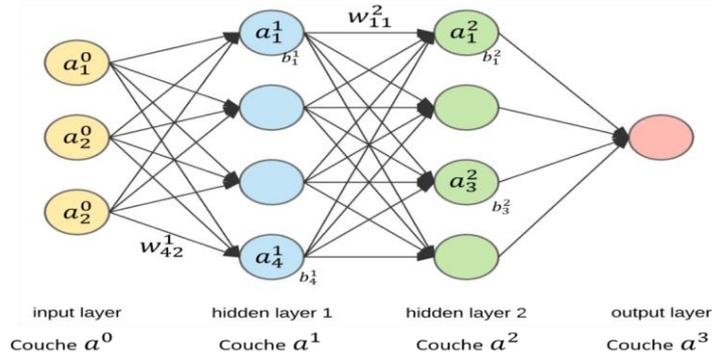


Figure II.9 : Architecture Perceptron Multi couches. [24]

5.3. Réseau de neurones récurrents

L'idée derrière les RNN est d'utiliser des informations séquentielles. Dans un réseau neuronal traditionnel, nous supposons que toutes les entrées (et les sorties) sont indépendantes les unes des autres. Mais pour de nombreuses tâches, c'est une très mauvaise idée. Si on veut prédire le prochain mot dans une phrase, il faut connaître les mots qui sont venus avant. Les RNN sont appelés récurrents, car ils exécutent la même tâche pour chaque élément d'une séquence, la sortie étant dépendante des calculs précédents.

Une autre façon de penser les RNN est qu'ils ont une « mémoire » qui capture l'information sur ce qui a été calculé jusqu'ici. En théorie, les RNN peuvent utiliser des informations dans des séquences arbitrairement longues, mais dans la pratique, on les limite à regarder seulement quelques étapes en arrière. Il est utilisé pour :

- La modélisation du langage et génération de texte.
- La traduction automatique.
- La reconnaissance vocale Et la description des images.[25]

Comme les réseaux de neurones récurrents possèdent de nombreuses connexions, on utilise souvent des représentations simplifiées où une seule flèche représente une matrice de poids W complète. La figure suivante représente ainsi un réseau classique, avec une couche récurrente suivie d'une couche dense classique :

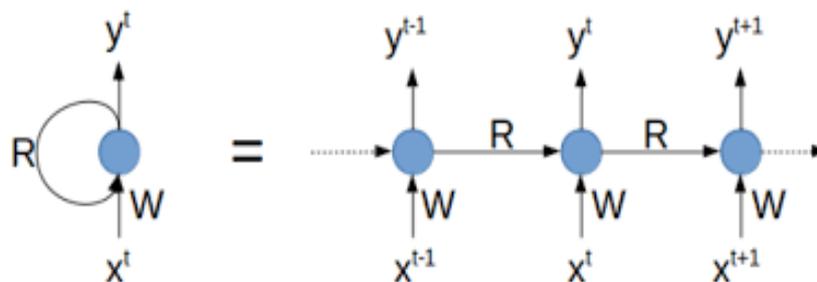


Figure II.10 : RNN simple, avec une couche récurrente et une couche dense. [26]

Chapitre II L'apprentissage Profond (Deep Learning)

5.4. Réseaux de neurones convolutifs (CNN)

Les réseaux de neurones convolutifs sont à ce jour les modèles les plus performants pour classer des images. Désignés par l'acronyme CNN, de l'anglais Convolutional Neural Network, ils comportent deux parties bien distinctes.

En entrée, une image est fournie sous la forme d'une matrice de pixels. Elle a deux dimensions pour une image aux niveaux de gris.

La couleur est représentée par une troisième dimension, de profondeur 3 pour représenter les couleurs fondamentales [Rouge, Vert, Bleu].

La première partie d'un CNN est la partie convolutive à proprement parler. Elle fonctionne comme un extracteur de caractéristiques des images. Une image est passée à travers d'une succession de filtres, ou noyaux de convolution, créant de nouvelles images appelées cartes de convolutions. Certains filtres intermédiaires réduisent la résolution de l'image par une opération de maximum local. En fin, les cartes de convolutions sont mises à plat et concaténées en un vecteur de caractéristiques, appelé code CNN.

Ce code CNN en sortie de la partie convolutive est ensuite branché en entrée d'une deuxième partie, constituée de couches entièrement connectées. Le rôle de cette partie est de combiner les caractéristiques du code CNN pour classer l'image.

La sortie est une dernière couche comportant un neurone par catégorie. Les valeurs numériques obtenues sont généralement normalisées entre 0 et 1, de somme 1, pour produire une distribution de probabilité sur les catégories.

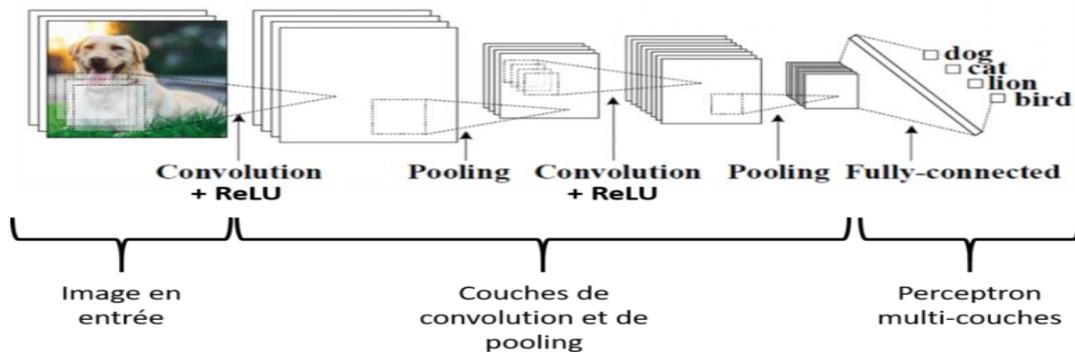


Figure II.11 : Réseau de neurones à convolution (CNN). [24]

6. Conclusion

Dans ce chapitre, nous avons appris la relation et la différence entre l'apprentissage en Profondeur et l'apprentissage automatique et l'intelligence artificielle. Nous avons également mentionné les types d'apprentissage automatique et les algorithmes qui sont utilisés, puis nous avons abordé les classes uniques dans les modèles de DL et d'apprentissage en profondeur.

Chapitre III

CNN et Transfer Learning

1. Introduction

La méthode de classification supervisée par les réseaux de neurones multicouches (perceptron) effectue un apprentissage à partir d'un ensemble de données prototypes (exemples des classes) où chaque donnée est décrite par un ensemble d'attributs. La difficulté de choisir les attributs et le nombre de couches, généralement faible (1 à 2 couches), fait que les performances atteintes par le perceptron multicouches sont limitées. D'autres méthodes d'apprentissage profond ou Deep learning, apprentissage peu profond) ont été proposées. Ces méthodes permettent d'éviter les inconvénients cités précédemment et sont actuellement très en vogue. [27]

La plupart des méthodes de Deep Learning utilisent des architectures de réseaux de neurones, ce qui explique pourquoi il est souvent question de réseaux de neurones profonds pour désigner des modèles de Deep Learning. Le terme « profond » revient au nombre de couches cachées du réseau de neurones.

Ces derniers comportent que 1 à 2 couches cachées, tandis que les réseaux profonds peuvent en compter jusqu'à 150. L'entraînement des modèles s'effectue à l'aide de vastes ensembles de données labellisées (prototypes) et d'architectures de réseaux de neurones qui apprennent des caractéristiques directement depuis les données, sans avoir à effectuer une extraction manuelle. [28]

Un des types de réseaux de neurones profonds le plus populaire est le réseau de neurones à convolution (Convolutional Neural Network ou CNN). Un CNN utilise des couches à convolution afin d'extraire des caractéristiques directement à partir des données. Son architecture est parfaitement adaptée au traitement des données matricielles telles que les images. Les réseaux de neurones à convolution éliminent la nécessité d'effectuer une extraction de caractéristiques manuelle, qui est généralement une tâche fastidieuse. Les caractéristiques utilisées ne sont pas pré-entraînées, c'est à dire que le réseau les apprend lui-même en s'entraînant sur des images. Cette extraction automatisée des caractéristiques permet aux CNN d'atteindre des performances élevées en classification d'objets. La complexité des caractéristiques apprises augmente avec le nombre de couches cachées du réseau. La première couche cachée peut par exemple apprendre à détecter les contours de l'image, tandis que la dernière apprend à détecter des formes plus complexes spécialement adaptées à la forme de l'objet que l'on vise à reconnaître. [27]

Nous allons décrire dans ce chapitre les réseaux de neurones à convolution et leurs applications à la classification des textures.

2. Définition

Les réseaux de neurones convolutionnels (ou CNN pour « Convolutional Neural Network ») sont une extension des MLP permettant de répondre efficacement aux principaux défauts des MLP. Ils sont conçus pour extraire automatiquement les caractéristiques des images d'entrée, sont invariants à de légères distorsions de l'image, et implémentent la notion de partage des poids permettant de réduire considérablement le nombre de paramètres du

réseau. Ce partage des poids permet en outre de prendre en compte de manière forte les corrélations locales contenues dans une image. Les poids sont forcés à être égaux pour détecter des lignes, des points ou des coins à tous les endroits possibles de l'image, implémentant de fait l'idée du partage des poids. [27]

3. Historique

Le premier réseau de neurones convolutif a été en réalité développé en 1998 par le chercheur français Yann LeCun. Ce réseau appelé LeNet a permis d'atteindre de très bonne performance en reconnaissance des caractères, Bien que cette approche donne des résultats, ses progrès et son évolution ont été limités par les progrès technologiques en matière de micro-processeurs, de puissance de calculs, et du manque d'accessibilités à des données afin de pouvoir entraîner les neurones.

Cependant certains chercheurs ont continué à travailler sur ce modèle pendant environ deux décennies. Et, avec l'aide des évolutions en matière de technologies mais surtout avec la disponibilité toujours plus grande de données, ont pu améliorer cette technique.

Ce n'est qu'en 2012 que le Deep Learning est remis au goût du jour en remportant avec succès le concours de reconnaissance d'image fondé par l'université de Stamford (Large Squalé Visual Recognition Challenge: ILSVRC) grâce à l'évolution en matière de technologies et à la disponibilité toujours plus grande de données. Un nouvel algorithme de Deep Learning explose les records Il s'agit d'un réseau de neurones convolutif appelé AlexNet, largement inspiré du réseau LeNet. ImageNet regroupant 15 000 000 d'images naturelles comportant différents objets et diverses scènes (véhicules, animaux,...).

Aujourd'hui, les réseaux de neurones convolutifs, sont toujours les modèles les plus performants pour la classification d'images. Google, Microsoft, Facebook, Baidu (le moteur de recherche chinois), Alibaba (site marchand chinois), Nvidia (géant du processeur graphique)...utilisent les CNN dans leurs applications. [28]

4. Architecture de CNN

Les réseaux de neurones à convolution sont basés sur le perceptron multicouche(MLP), et inspirés du comportement du cortex visuel des vertébrés. Bien qu'efficaces pour le traitement d'images, les MLP ont beaucoup de mal à gérer des images de grande taille, ce qui est dû à la croissance exponentielle du nombre de connexions avec la taille de l'image.

Un réseau de neurone convolutif se compose de plusieurs couches comme le montre la

figure III.1

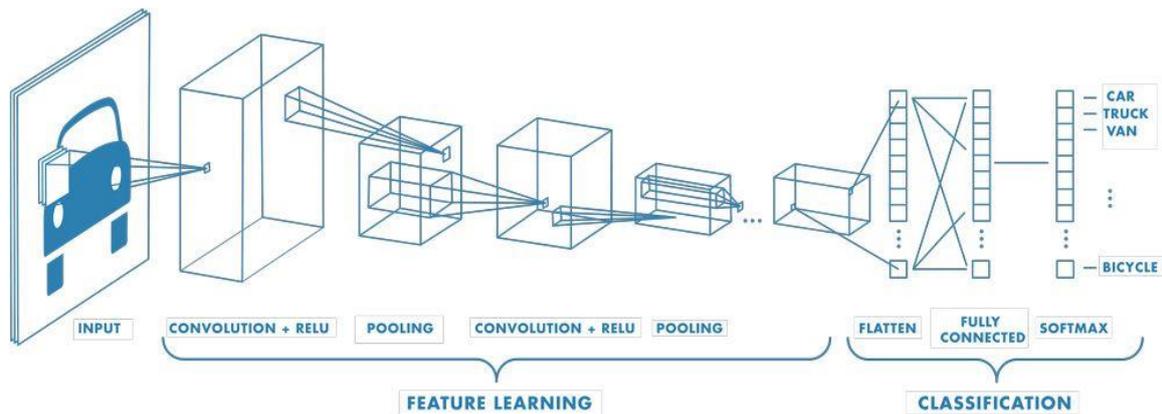


Figure III.1 :L'architecture d'un CNN.

• Couches CNN

Une architecture CNN est formée par un empilement de couches de traitement indépendantes :

- La couche de convolution (CONV) qui traite les données d'un champ récepteur.
- La couche de pooling (POOL), qui permet de compresser l'information en réduisant la taille de l'image intermédiaire (souvent par sous-échantillonnage).
- La couche de correction (ReLU), souvent appelée par abus 'ReLU' en référence à la fonction d'activation (Unité de rectification linéaire).
- La couche "entièrement connectée" (FC), qui est une couche de type perceptron.
- La couche de perte (LOSS).

5. Réseaux de neurones convolutionnels (CNN)

En apprentissage automatique, un réseau de neurone convolutifs (ou réseau de neurones à convolution, ou CNN ou ConvNet) sont un type de réseau de neurones spécialisés pour le traitement de données ayant une topologie semblable à une grille. Qui se sont avérés très efficaces dans des domaines tels que la reconnaissance et la classification d'images et vidéos. CNN a réussi à identifier les visages, les objets, panneaux de circulation et auto-conduite des voitures. Récemment, les CNN ont été efficaces dans plusieurs tâches de traitement du langage naturel (telles que la classification des phrases).[29]



Figure III.2 : Un cheval.

Lorsque nous transmettons l'image à un ordinateur, il la convertit essentiellement en une matrice de valeurs de pixels. Les valeurs de pixel vont de 0 à 255, et les dimensions de cette matrice seront de [largeur de l'image x hauteur de l'image x nombre de canaux].

Une image en niveaux de gris a un canal et les images colorées ont trois canaux rouge, vert et bleu (RVB).

Comme indiqué dans le diagramme suivant, l'image en niveaux de gris d'entrée sera convertie en une matrice de valeurs de pixels allant de 0 à 255, les valeurs de pixels représentant l'intensité des pixels à ce point :

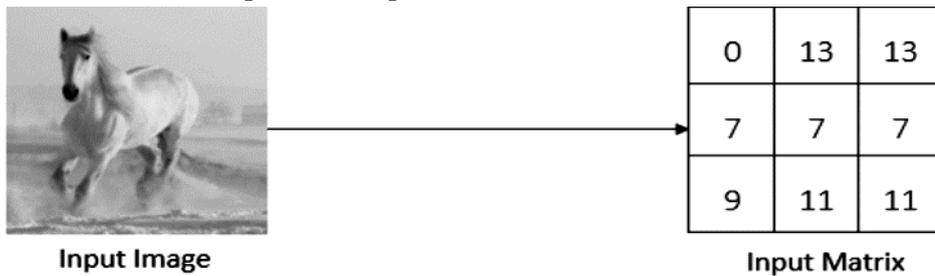


Figure III.3 : Image convertie en une matrice de valeurs de pixels.

D'accord, nous avons maintenant une matrice d'entrée de valeurs de pixels.

5.1. Couches convolutives

La couche convolutionnelle est la première couche centrale du CNN. C'est l'un des éléments constitutifs d'un CNN et est utilisé pour extraire des caractéristiques importantes de l'image.

C'est là que nous utilisons une opération de convolution qui va extraire toutes les caractéristiques importantes de l'image qui caractérisent le cheval. Ainsi, l'opération de convolution nous aide à comprendre en quoi consiste l'image.

Comme nous le savons, chaque image d'entrée est représentée par une matrice de valeurs de pixels. Outre la matrice d'entrée, nous avons également une autre matrice appelée matrice de filtre. La matrice de filtre est également connue sous le nom de noyau, ou simplement de filtre, comme illustré dans le diagramme suivant :



Figure III.4 : Exemple des valeurs des matrices et des filtres et pixel des images .

Nous prenons la matrice de filtre, la glissons sur la matrice d'entrée d'un pixel, effectuons une multiplication par élément, additionnons les résultats et produisons un seul nombre.

Comprenons mieux cela à l'aide du schéma suivant :

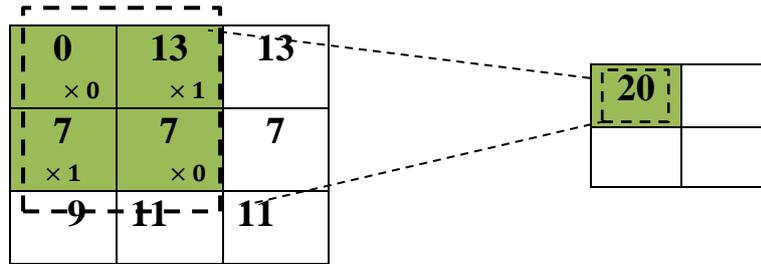


Figure III.5 : Opération de convolution.

Comme vous pouvez le voir dans le diagramme précédent, nous avons pris la matrice de filtre et l'avons placée au-dessus de la matrice d'entrée, effectué une multiplication élémentaire, additionné leurs résultats et produit le nombre unique. Ceci est démontré comme suit :

$$(0 * 0) + (13 * 1) + (7 * 1) + (7 * 0) = 20$$

Maintenant, encore une fois, nous faisons glisser la matrice de filtre sur la matrice d'entrée d'un pixel et effectuons la même opération, comme indiqué dans le diagramme suivant :

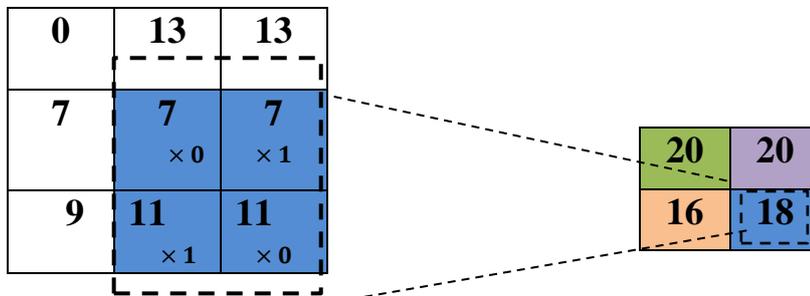


Figure III.6 : Opération de convolution.

Comme nous l'avons appris, l'opération de convolution est utilisée pour extraire des entités, et la nouvelle matrice, c'est-à-dire les cartes d'entités, représente les entités extraites. Si nous traçons les cartes de caractéristiques, nous pouvons voir les caractéristiques extraites par l'opération de convolution.[30]

Le diagramme suivant montre l'image réelle (l'image d'entrée) et l'image convoluée (la carte des caractéristiques). Nous pouvons voir que notre filtre a détecté les bords de l'image réelle comme une caractéristique :



Figure III.7 : l'image réelle (l'image d'entrée) et l'image convoluée.

5.2. Couche unité rectifié linéaire (Relu)

Un élément important dans l'ensemble du processus est l'Unité linéaire rectifiée ou Relu. Les mathématiques derrière ce concept sont assez simples encore une fois : chaque fois qu'il y a une valeur négative dans un pixel, on la remplace par un 0. Ainsi, on permet au CNN de rester en bonne santé (mathématiquement parlant) en empêchant les valeurs apprises de rester coincer autour de 0 ou d'exploser vers l'infinie.

C'est un outil fondamental car sans lequel le CNN ne produirait pas vraiment les résultats qu'on lui connaît.

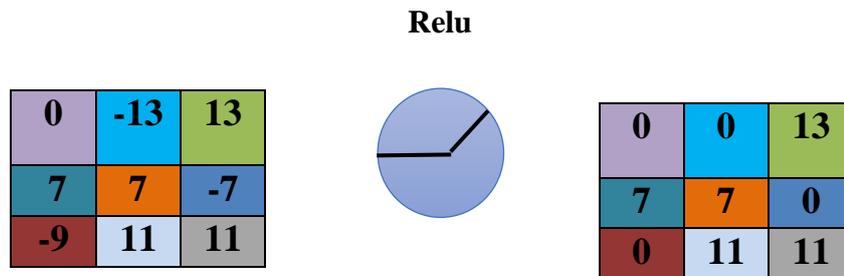


Figure III.8 : l'Unité linéaire rectifiée (Relu) .

Le résultat d'une couche Relu est de la même taille que ce qui lui est passé en entrée, avec simplement toutes les valeurs négatives éliminées.

5.3. Couche Pooling

Un autre outil très puissant utilisé par les CNN s'appelle le Pooling. Le Pooling est une méthode permettant de prendre une large image et d'en réduire la taille tout en préservant les informations les plus importantes qu'elle contient. Les mathématiques derrière la notion de pooling ne sont une nouvelle fois pas très complexes. En effet, il suffit de faire glisser une petite fenêtre pas à pas sur toutes les parties de l'image et de prendre la valeur maximum de cette fenêtre à chaque pas. Après avoir procédé au pooling, l'image n'a plus qu'un quart du nombre de ses pixels de départ parce qu'il garde à chaque pas la valeur maximale contenue dans la fenêtre, il préserve les meilleures caractéristiques de cette image. Cela signifie qu'il ne se préoccupe pas vraiment d'où a été extraite la caractéristique dans l'image.

Le résultat est que le CNN peut trouver si une caractéristique est dans une image, sans se soucier de l'endroit où elle se trouve.

Il existe plusieurs types de pooling :

- Le max pooling.
- Le mean pooling.
- Le sum pooling.[30]

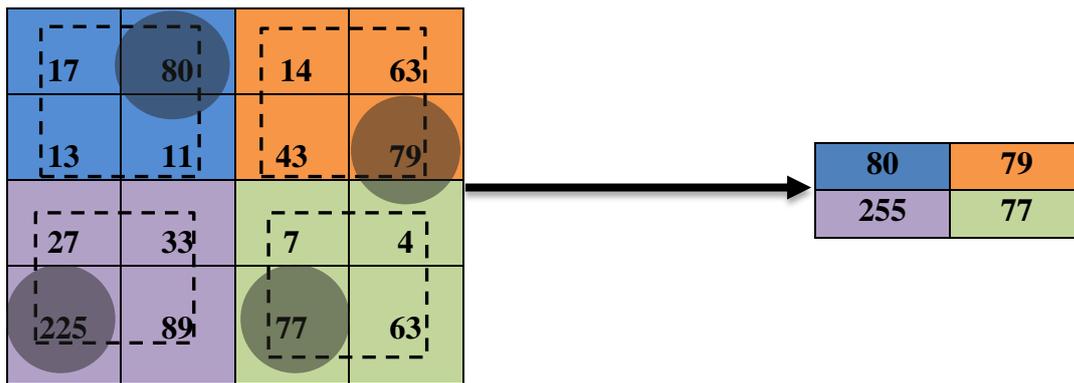


Figure III.9 : Exemple du Max Pooling .

5.4. Couche entièrement connectée

L'ensemble successives des cartes de convolutions, pooling et ReLu fournissent au final un ensemble de caractéristiques données sous forme de carte 2D. Ces cartes sont concaténées en un vecteur de caractéristiques, appelé code CNN. Ce code CNN en sortie de la partie convolutive est ensuite branché en entrée d'une deuxième partie, constituée d'une ou de plusieurs couches entièrement connectées (fullyconnected ou FC) qu'on peut assimiler au perceptron multicouche. Les neurones dans une couche entièrement connectée ont des connexions vers les sorties de la couche précédente.

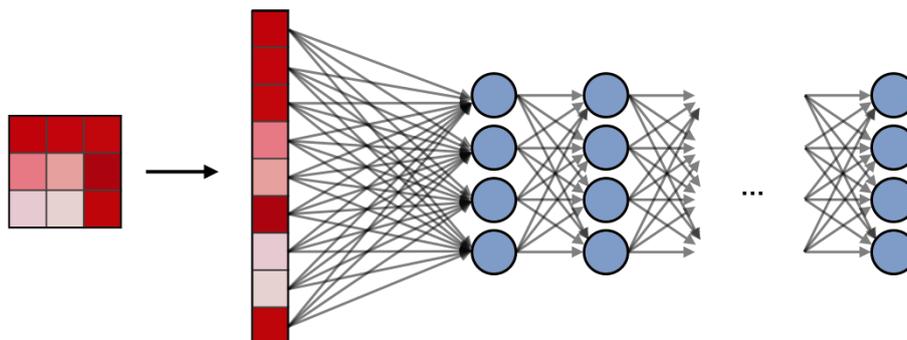


Figure III.10 : La couche entièrement connectée.[31]

5.5. Couche de perte (LOSS)

La couche de perte suit la couche entièrement connectée et gère les ajustements de poids sur le réseau. Avant que l'entraînement du réseau ne commence, les poids des couches convolution et entièrement connectées reçoivent des valeurs aléatoires. Ensuite, pendant l'entraînement, la couche de perte vérifie en permanence les suppositions de la couche entièrement connectée par rapport aux valeurs réelles dans le but de minimiser autant que possible la différence entre l'estimation et la valeur réelle. La couche de perte effectue cela en ajustant les poids à la fois dans la couche de convolution et dans les couches entièrement connectées.

Maintenant, nous devons classer ces fonctionnalités extraites. Nous avons donc besoin d'un algorithme capable de classer ces entités extraites et de nous dire si les entités extraites

sont les caractéristiques d'un cheval, ou autre chose. Afin de faire cette classification, nous utilisons un réseau de neurones feedforward.

Nous aplatissons la carte des caractéristiques et la convertissons en vecteur, et la fournissons en tant qu'entrée au réseau anticipé. Le réseau à anticipation prend cette carte de caractéristiques aplatie comme entrée, applique une fonction d'activation, telle que sigmoïde, et renvoie la sortie, indiquant si l'image contient un cheval ou non ; cela s'appelle une couche entièrement connectée et est illustré dans le diagramme suivant :

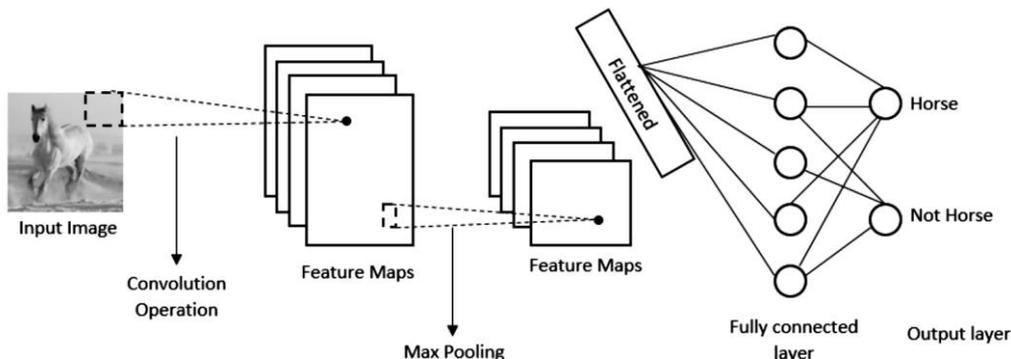


Figure III.11 : les étapes de La couche entièrement connectée.

5.6. Algorithme d'apprentissage en profondeur

Au début de chaque problème d'apprentissage en profondeur, nous avons un ensemble de données et un modèle en grande partie non entraîné. En général, nous avons une base de données à partir de laquelle nous obtenons des caractéristiques, des images, et des étiquettes - également appelées vérités terrain ou cibles, décrivant par exemple ce qui se trouve sur l'image.

Nous envoyons les caractéristiques dans le réseau de neurones et le laissons faire une prédiction sur ces données. Nous comparons ensuite la prédiction avec les vraies étiquettes de la base de données en calculant la perte (Loss).

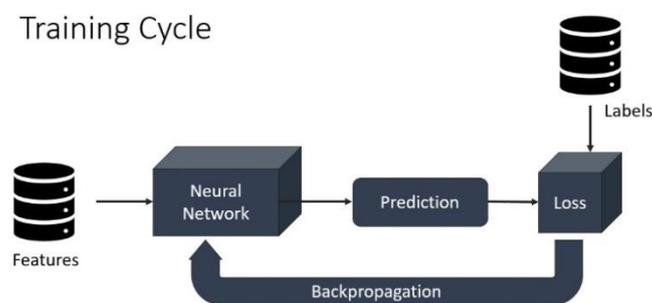


Figure III.12 : Algorithme d'apprentissage.

5.6.1. Rétropropagation (Backpropagation)

La rétropropagation est l'essence de la formation des réseaux de neurones. C'est la méthode d'ajustement des poids d'un réseau de neurones en fonction du taux d'erreur (Loss) obtenu à l'époque précédente. Un réglage approprié des poids permet de réduire les taux d'erreur et de rendre le modèle fiable en augmentant sa généralisation.

L'algorithme de rétropropagation dans le réseau de neurones calcule le gradient de la fonction de perte pour un seul poids par la règle de la chaîne. Il calcule efficacement une couche à la fois, contrairement à un calcul direct natif. Il généralise le calcul dans la règle delta.

Considérez le diagramme d'exemple de réseau neuronal de rétropropagation suivant pour comprendre :

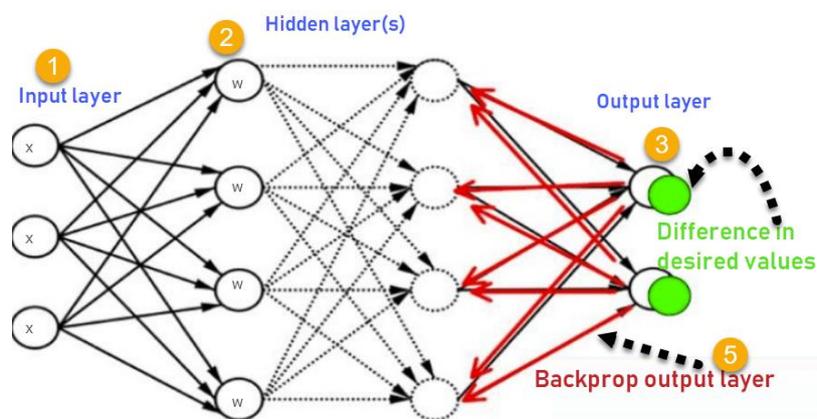


Figure III.13 : L'algorithme de rétro propagation

1. Entrées X, arrivent par le chemin pré connecté de la couche d'entrée
2. L'entrée est modélisée à l'aide de poids réels W. Les poids sont généralement sélectionnés au hasard.
3. Calculez la sortie pour chaque neurone de la couche d'entrée, aux couches cachées, puis la couche de sortie.
4. Calculer l'erreur dans les sorties
 $\text{Erreur} = \text{Sortie réelle} - \text{Sortie souhaitée}$
5. Revenez de la couche de sortie vers la couche cachée pour ajuster les poids de manière à réduire l'erreur.
6. Répéter le processus jusqu'à ce que le résultat souhaité soit atteint.

5.6.2. Époques, itérations et Batch

Itération : chaque cycle lors d'une mise à jour peut être appelée une itération. On peut dire qu'une itération est terminée chaque fois que les poids du réseau sont mis à jour ou chaque fois que nous faisons une prédiction.

Époque : Une époque est terminée une fois que le réseau de neurones a vu toutes les données une fois.

Batch (taille du lots de données) : En principe l'ensemble de données complet est utilisé à la fois (Descente de dégradé classique par lots complets). En général, l'espace mémoire dont nous disposons est souvent trop réduit. Les réseaux de neurones modernes sont déjà assez volumineux eux-mêmes. Comme solution, le lots des donnees peut etre divise en petit lots (mini-batches), puis accumuler les gradients et ne faire la mise à jour qu'à la fin, mais cela prendrait extrêmement longtemps, car Gradient Descent prend de nombreuses étapes d'entraînement pour devenir optimum.

- Les mini-lots sont le plus souvent utilisés
- La taille exacte du lot dépend de votre projet et vous devriez en essayer différents pour voir lequel fonctionne le mieux dans chaque cas.

Une bonne ligne directrice consiste à choisir des exponentielles de 2 (par exemple 16, 32, 64, ...) pour la taille de votre lot car cela utilise la mémoire le plus efficacement.

5.7. Architecture des CNN les plus connus

Il existe un grand nombre de réseaux CNN pré entraînés, les plus connus sont :

Model	Size	Top-1 Accuracy	Top-5 Accuracy	Parameters	Depth
Xception	88 MB	79%	95%	22,910,480	126
VGG16	528 MB	72%	90%	138,357,544	23
VGG19	549 MB	73%	91%	143,667,240	26
ResNet50	99 MB	76%	93%	25,636,712	168
InceptionV3	92 MB	79%	94%	23,851,784	159
InceptionResNetV2	215 MB	80%	95%	55,873,736	572
MobileNet	17 MB	67%	87%	4,253,864	88
DenseNet121	33 MB	75%	92%	8,062,504	121
DenseNet169	57 MB	76%	93%	14,307,880	169
DenseNet201	80 MB	77%	93%	20,242,984	201

Tableau III.1 : Les architectures de CNN.

6. Transfert Learning

L'apprentissage par transfert (TL) est un problème de recherche en apprentissage automatique (ML) qui se concentre sur le stockage des connaissances acquises lors de la résolution d'un problème et de son application à un problème différent mais connexe, comme les connaissances acquises lors de l'apprentissage de la reconnaissance des voitures pourraient être appliquées lors de la tentative de reconnaissance des camions. Ce domaine de recherche a un certain rapport avec la longue histoire de la littérature psychologique sur le transfert de l'apprentissage, bien que les liens pratiques entre les deux domaines soient limités. D'un point de vue pratique, la réutilisation ou le transfert d'informations à partir de tâches précédemment apprises pour l'apprentissage de nouvelles tâches a le potentiel d'améliorer considérablement l'efficacité de l'échantillon d'un agent d'apprentissage. Le transfert de l'apprentissage est utilisé

Lorsque nous n'avons pas suffisamment de données annotées pour entraîner notre modèle. Lorsqu'il existe un modèle préformé qui a été formé sur des données et des tâches similaires.

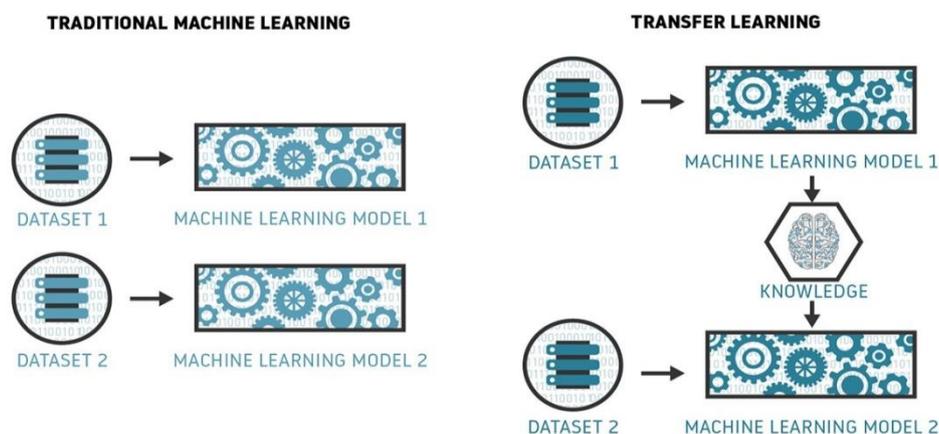


Figure III.14 : Traditional Machine Learning vs Transfer Learning. [32]

6.1. Principe de transfert d'apprentissage

En vision par ordinateur, les réseaux de neurones visent généralement à détecter les contours dans la première couche, les modèles dans la couche intermédiaire et les caractéristiques spécifiques à une tâche dans les dernières couches. La première couche et la couche centrale sont utilisées pour le transfert d'apprentissage, et seules les dernières couches sont recyclées. Il tire parti des données étiquetées de la tâche entraînée.

Revenons à l'exemple d'un modèle qui était destiné à identifier un sac à dos dans une image et qui sera désormais utilisé pour détecter des lunettes de soleil. Étant donné que le modèle s'est entraîné à reconnaître les objets dans les niveaux précédents, nous allons simplement recycler les couches suivantes pour comprendre ce qui distingue les lunettes de soleil des autres objets.

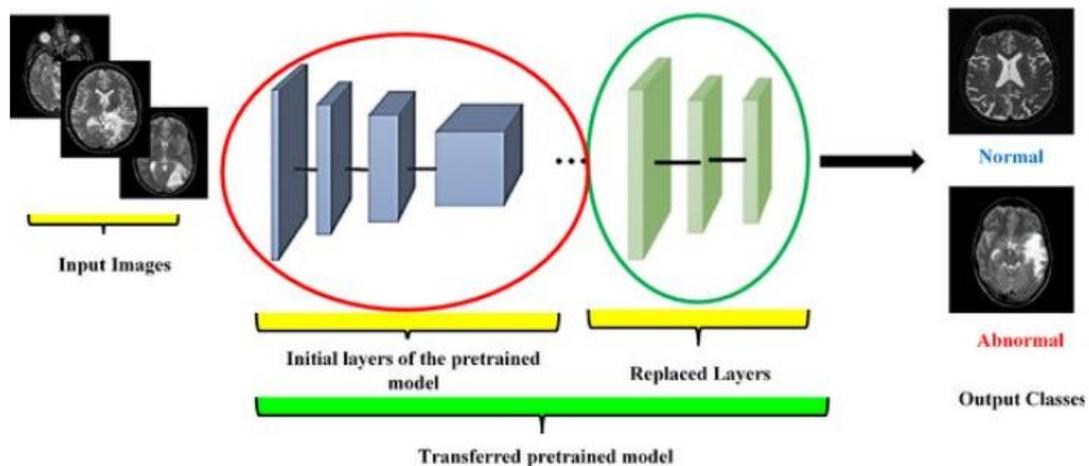


Figure III.15 : Transfer Learning.

6.2. Entraînement du modèle

Considérez la situation dans laquelle vous souhaitez aborder la tâche A mais ne disposez pas des données nécessaires pour former un réseau de neurones profonds. Trouver une tâche connexe B avec beaucoup de données est une méthode pour contourner ce problème.

Utilisez le réseau neuronal profond pour vous entraîner à la tâche B, puis utilisez le modèle pour résoudre la tâche A. Le problème que vous cherchez à résoudre décidera si vous devez utiliser le modèle entier ou seulement quelques couches.

Si l'entrée dans les deux tâches est la même, vous pouvez réappliquer le modèle et faire des prédictions pour votre nouvelle entrée. Changer et recycler des couches spécifiques à des tâches distinctes et la couche de sortie, d'autre part, est une approche à étudier.

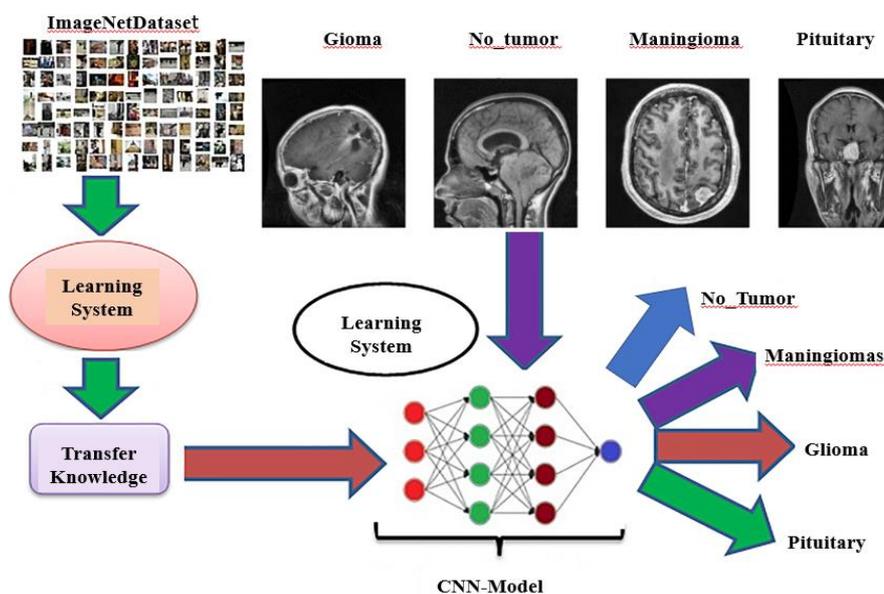


Figure III.16 : Entraînement par Transfer Learning.

6.3. Contourner l'overfitting

L'overfitting est dû au fait que l'on dispose de trop peu de données. Le modèle a trop peu de cas d'usage différent ce qui rend difficile son entraînement. Par conséquent il ne peut pas développer des règles de décisions pouvant être généralisé à de nouvelles données.

il existe une technique pour augmenter notre nombre de données. On peut créer des images artificielles grâce à la Data Augmentation (littéralement : l'augmentation des données).

Pour pallier a ce problème d'overfitting, plusieurs techniques sont utilisées.

6.3.1. Data Augmentation

Data Augmentation (Augmentation des données) est de reproduire les données préexistantes en leur appliquant une transformation aléatoire. Par exemple, appliquer un effet miroir sur une image.

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. Cela lui permet de mieux généraliser.

6.3.2. Dropout

L'idée du Dropout est de supprimer aléatoirement certains neurones et donc supprimer les poids associés. En écartant certains neurones lors de l'apprentissage, les autres neurones sont contraints de se surpasser pour que la couche donne de bons résultats. Cela peut paraître paradoxale mais cette technique permet d'améliorer l'apprentissage du modèle.

6.3.3. Early Stopping

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

6.3.4. ReduceLROnPlateau

Cette technique 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. Ce callback surveille une quantité et si aucune amélioration n'est constatée pendant un nombre d'époques 'patience', le taux d'apprentissage est réduit.

6.3.4. 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.

7. Matrice de confusion

Le Machine Learning consiste à fournir à un algorithme des données afin qu'il apprenne par lui-même à effectuer une certaine tâche. Dans les problèmes de classification, il prédit des résultats que l'on doit comparer à la réalité pour mesurer son degré de performance. On utilise généralement la matrice de confusion, appelée aussi tableau de contingence. Elle mettra non seulement en valeur les prédictions correctes et incorrectes mais nous donnera surtout un indice sur le type d'erreurs commises. Pour calculer une matrice de confusion, on a besoin d'un ensemble de données de test et un autre de validation qui contient les valeurs des résultats obtenus.

Chaque colonne du tableau contient une classe prédite par l'algorithme et les lignes des classes réelles.

On classe les résultats en 4 catégories :

- **True Positive (TP)** : la prédiction et la valeur réelle sont positives.

Exemple : Une personne malade et prévu malade.

- **True Negative (TN)** : la prédiction et la valeur réelle sont négatives.

Exemple : Une personne saine et prévu saine.

- **False Positive (FP)** : la prédiction est positive alors que la valeur réelle est négative.

Exemple : Une personne saine et prévu malade.

- **False Negative (FN)** : la prédiction est négative alors que la valeur réelle est négative.

Exemple : Une personne malade et prévu saine.

	Predicted 0	Predicted 1
Actual 0	TN	FP
Actual 1	FN	TP

Figure III.17 : Matrice de confusion.

8. Mesures utilisant la matrice de confusion et leur signification

Les principales métriques qui nous aident à décider si le classifieur a fait les bonnes prédictions sont :

8.1. Rappel/Sensibilité

Le rappel ou la sensibilité ou le taux de vrais positifs (TPR) ou la probabilité de détection est le rapport entre les prédictions positives correctes (TP) et le total des positifs (c'est-à-dire, TP et FN).

$$R = \frac{TP}{TP + FN}$$

Le rappel est la mesure des résultats positifs corrects renvoyés par rapport au nombre de résultats positifs corrects qui auraient pu être produits. Une valeur plus élevée de Rappel signifie qu'il y a moins de faux négatifs, ce qui est bon pour l'algorithme. Utilisez Rappel lorsque la connaissance des faux négatifs est importante. Par exemple, si une personne a plusieurs blocages au niveau du cœur et que le modèle montre qu'il va parfaitement bien, cela pourrait s'avérer fatal.

8.2. Précision

La précision est la mesure des résultats positifs corrects parmi tous les résultats positifs prédits, y compris les vrais et les faux positifs.

$$Pr = \frac{TP}{TP + FP}$$

La précision est très importante lorsque les faux positifs sont trop importants pour être ignorés. Par exemple, si une personne n'a pas de diabète, mais que le modèle le montre et que le médecin prescrit certains médicaments. Cela peut entraîner des effets secondaires graves.

8.3. Spécificité

La spécificité ou taux de vrais négatifs (TNR) correspond aux résultats négatifs corrects trouvés parmi tous les résultats qui auraient pu être négatifs.

$$S = \frac{TN}{TN + FP}$$

Il s'agit d'une mesure de la capacité de votre classificateur à identifier les valeurs négatives.

8.4. Accuracy

La précision est le nombre de prédictions correctes sur le nombre total de prédictions. Ainsi, si vous avez trouvé correctement 20 valeurs positives et 10 valeurs négatives à partir d'un échantillon de 50, la précision de votre modèle sera de 30/50.

$$A = \frac{TP + TN}{TP + TN + FP + FN}$$

8.5. Prévalence

La prévalence est la mesure du nombre de résultats positifs obtenus sur l'ensemble des résultats.

$$P = (TP + FN) / (TP + TN + FP + FN)$$

8.6. F-Score

$$\text{Score F1} = (2 * \text{Précision} * \text{Rappel}) / (\text{Précision} + \text{Rappel})$$

Il s'agit d'une moyenne harmonique entre la précision et le rappel, et nous pouvons utiliser le score f1 lorsque nous ne savons pas réellement si FP est important ou FN est important dans notre problème.

Autres métriques

$$\text{Taux Vrai Négatif (TNR)} = TN / (TN + FP)$$

$$\text{Taux de faux positifs (FPR)} = FP / (FP + TN)$$

9. Conclusion

Dans ce chapitre, les réseaux de neurones à convolution ont été définis et leur rôle a été mis en relief. Ces réseaux sont capables d'extraire des caractéristiques d'images ou des données en général, présentées en entrée et de classifier ces données en se basant sur les caractéristiques (de ces données) extraites automatiquement. Ils implémentent aussi l'idée de l'apprentissage par transfert qui permet de réduire beaucoup le nombre de paramètres libres de l'architecture. Le Transfer Learning permet en outre de réduire les temps de calcul et l'espace mémoire nécessaire et également d'améliorer les capacités de généralisation du réseau. Le chapitre suivant sera consacré à la discussion des résultats et les outils de programmation utilisés pour résoudre notre problème de détection des tumeurs par le CNN et le Transfer Learning.

Chapitre IV
Implémentation
et Résultats

1. Introduction

Dans cette section, les détails des méthodes et des algorithmes de l'approche proposée pour la classification des images IRM du cerveau sont expliqués. Pour valider notre approche, l'exactitude, la précision, le rappel et la mesure F1 sont calculés dans le cadre d'une expérience contrôlée. Le langage Python est utilisé pour mener une expérience contrôlée.

Dans ce travail, nous allons présenter deux expériences de classification en utilisant le CNN conventionnel et différents modèles pré-entraîner pour l'extraction des caractéristiques.

- Classification binaires : le modèle proposé vise à classer les images IRM cérébrales en deux classes, les images avec tumeur et les images sans tumeur cérébrale ou saines en utilisant un CNN conventionnel et le Transfer Learning de type (MobileNet).
- Classification multi-classe : Un ensemble de données contenant 394 images cérébrales d'imagerie par résonance magnétique (IRM) comprenant des images de gliome, de méningiome, de tumeurs de l'hypophyse et de cerveaux sains a été utilisé dans cette étude.

Tout d'abord, différentes étapes de prétraitement sont appliquées aux images IRM pour l'augmentation et l'amélioration de l'image. Les ensembles de données sont ensuite divisés en ensembles d'apprentissage, de validation et de test. Les architectures CNN pré-entraînées sont utilisées pour tester et évaluer le modèle proposé.

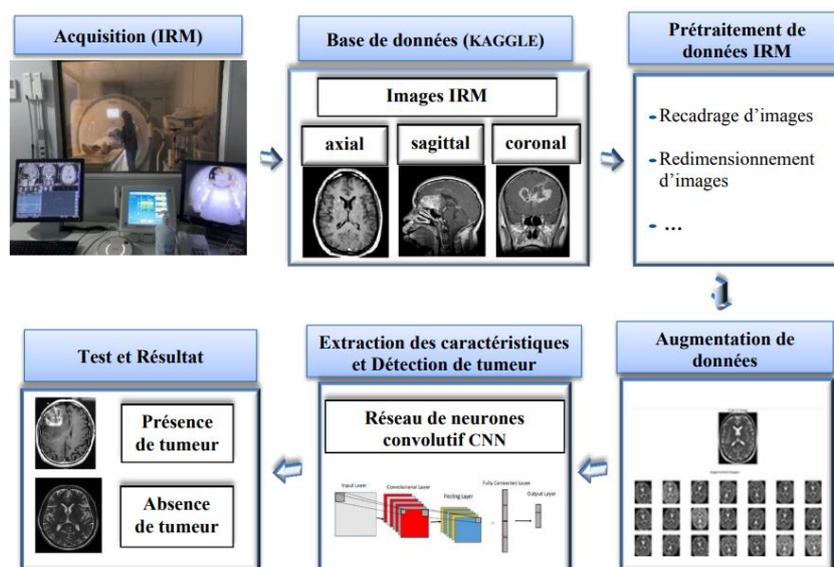


Figure IV.1 : le schéma fonctionnel de la méthode proposée.

La **FIGURE IV.1** montre le schéma fonctionnel de la méthode proposée, dans laquelle le système commence à charger et à extraire des images et des étiquettes à partir de fichiers bruts d'ensembles de données, puis à effectuer des techniques de prétraitement et d'augmentation juste après avoir divisé l'ensemble de données en ensembles d'apprentissage, de validation et de test. Ensuite, la structure de la méthode proposée est introduite, suivie de la définition des hyper-paramètres, des techniques de régularisation et de l'algorithme d'optimisation. Enfin, l'apprentissage du réseau et les calculs de performances sont présentés.

2. Configuration du matériel utilisé

La configuration du matériel utilisé dans notre implémentation est composée de :

- Un PC portable HP
- RAM de taille 32 GO
- Disque dur de taille 600 GO
- Système d'exploitation windows 10 version

3. Application1 : Classification Binaire

Dans cette expérience on va classer les images IRM cérébrales en deux catégories, les images avec tumeur et les images sans tumeur cérébrale ou saines en utilisant un CNN conventionnel puis un modèle CNN pré-entraîne (MobileNet).

3.1. Acquisition de la base de données

L'ensemble de données utilisé pour la formation et les tests a été collecté auprès de Kaggle. Il contient des images d'IRM cérébrales dans lesquelles certaines d'entre elles sont des images contenant une tumeur (images tumorales) et certaines images sont normales (sans tumeur). Les images tumorales sont séparées dans le dossier nommé "Tumeur cérébrale" et les images normales sont conservées dans le dossier "sain". Les images sont de différents formats et de tailles variables.

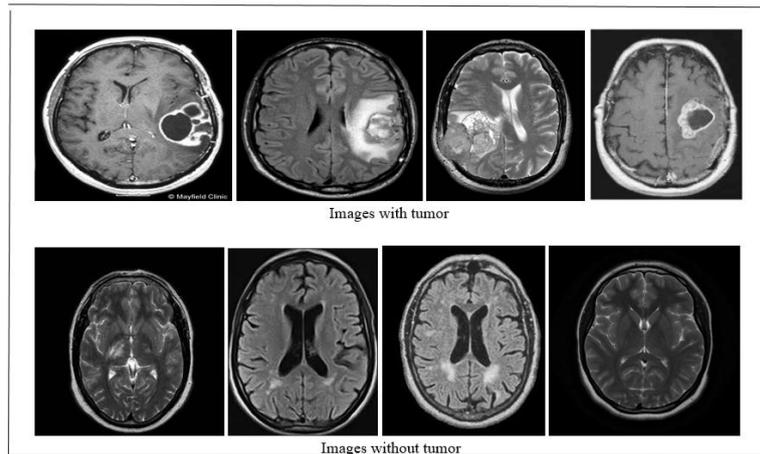


Figure IV.2 : Image (IRM) du cerveau avec tumeur et sans tumeur.

3.2. Modèles proposés

Avant d’entraîner le modèle, l’ensemble de données a été divisé en trois parties Training, Validation et Test. Les données Training sont utilisées pour former le modèle et les données de Test et les données de Validation ont été utilisées pour tester le modèle. Dans ce projet, 70 % des données ont été prises comme données d’entraînement et 15 % ont été prises comme données de Test ainsi que 15 % comme données de Validation.

Dans l’étape suivante, les données sont augmentées et redimensionnées de largeur 200, hauteur 200 et canal 3 (RVB). De plus on a appliqué la technique de Early_stopping et Dropout pour éviter l’overfitting.

3.2.1. Réseaux de neurones convolutifs (CNN)

Dans cette expérience nous avons proposé notre propre CNN. L’architecture du model est visualise dans la figure suivante.

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 196, 196, 32)	2432
max_pooling2d (MaxPooling2D)	(None, 98, 98, 32)	0
conv2d_1 (Conv2D)	(None, 96, 96, 64)	18496
max_pooling2d_1 (MaxPooling2D)	(None, 48, 48, 64)	0
conv2d_2 (Conv2D)	(None, 46, 46, 128)	73856

max_pooling2d_2 (MaxPooling2	(None, 23, 23, 128)	0
conv2d_3 (Conv2D)	(None, 21, 21, 256)	295168
max_pooling2d_3 (MaxPooling2	(None, 10, 10, 256)	0
dropout (Dropout)	(None, 10, 10, 256)	0
flatten (Flatten)	(None, 25600)	0
dropout_1 (Dropout)	(None, 25600)	0
dense (Dense)	(None, 256)	6553856
dense_1 (Dense)	(None, 1)	257

Total params: 6,944,065

Trainable params: 6,944,065

Non-trainable params: 0

Found 2090 images belonging to 2 classes (Training).

Found 440 images belonging to 2 classes (validation).

Found 440 images belonging to 2 classes (Test).

3.2.2. Resultats du modele CNN

A- Nombre d'epochs = 10 avec early stopping

Accuracy	Loss	Resultat
<p>The accuracy is : 82.95454382896423 %</p>		<p>The MRI scan has a tumor</p>

Figure IV.3 : Graphique représentant la précision et la perte de modèle CNN pour l'ensemble d'entraînement et de validation pour 10 epochs.

B- Nombre d'epochs = 35 avec early stopping

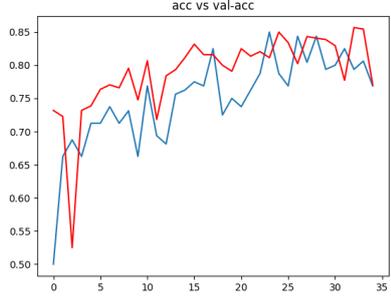
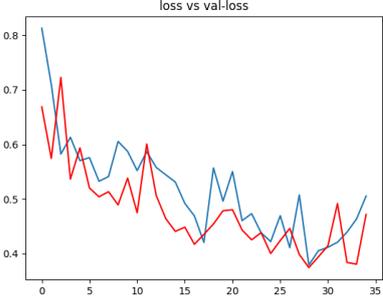
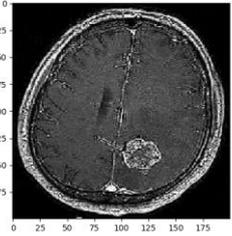
Accuracy	Loss	Resultat
		
<p style="text-align: center;">The accuracy is : 89.77272510528564 %</p>		<p style="text-align: center;">The MRI scan has a tumor</p>

Figure IV.4 : Graphique représentant la précision et la perte de modèle CNN pour l'ensemble d'entraînement et de validation pour 35 epochs.

Le modèle CNN donne une exactitude (accuracy) meilleure pour in nombre d'epoches plus grand.

82.95454382896423% pour 10 epochs

89.77272510528564 % pour 35 epochs

Dans cette deuxième expérience nous allons utiliser un modèle pré-entraîne pour améliorer les performances de notre système.

3.2.3. Modèle pré-entraîne : MobileNet

Dans ce deuxième cas, nous avons utilisé des architectures CNN pré-entraînées appelées MobileNet, qui est un type de réseau neuronal convolutif conçu pour les applications de vision mobile et embarquée comme indique dans la Figure IV.5 :

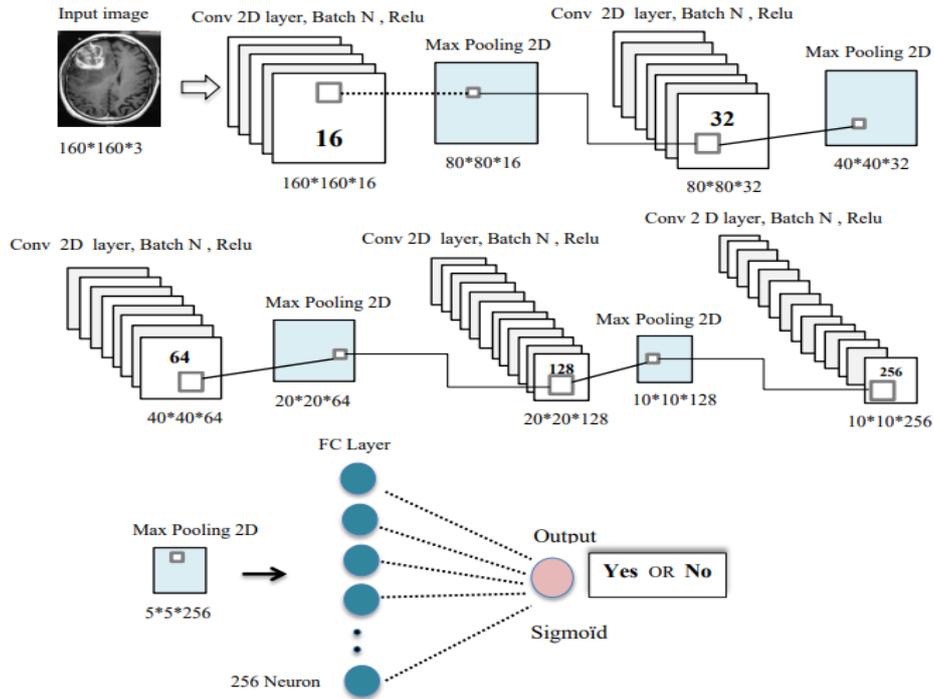


Figure IV.5 : CNN pré-entraînée MobileNet.

3.2.4. Résultats de MobileNet

A- Nombre d'epochs = 20 avec early stopping

Accuracy	Loss	Resultat
<p>The accuracy is : 98.18181991577148 %</p>		<p>The MRI scan has no tumor</p>

Figure IV.6 : Graphique représentant la précision et la perte de modèle pour l'ensemble d'entraînement et de validation utilisant l'approche MobileNet.

L'utilisation de MobileNet comme modèle de base a permis d'augmenter la précision jusqu' à 98 %.

4. Application2 : Classification Multi-classe

Le défi majeur se pose dans la détection de la tumeur cérébrale en raison de l'emplacement, du type, de la taille et des variations de forme de la tumeur. Le diagnostic de tumeur cérébrale dépend du type et de l'emplacement de la tumeur afin que les médecins puissent prédire les chances de survie des patients et prendre des décisions de traitement allant de la chirurgie à la radiothérapie et à la chimiothérapie.

Le modèles pré-entraîner que nous allons appliquer dans cette expérience est de type Inception-ResNet-v2 qui va nous permettre de classifier les 4 types de tumeurs indiqués dans la figure suivante :

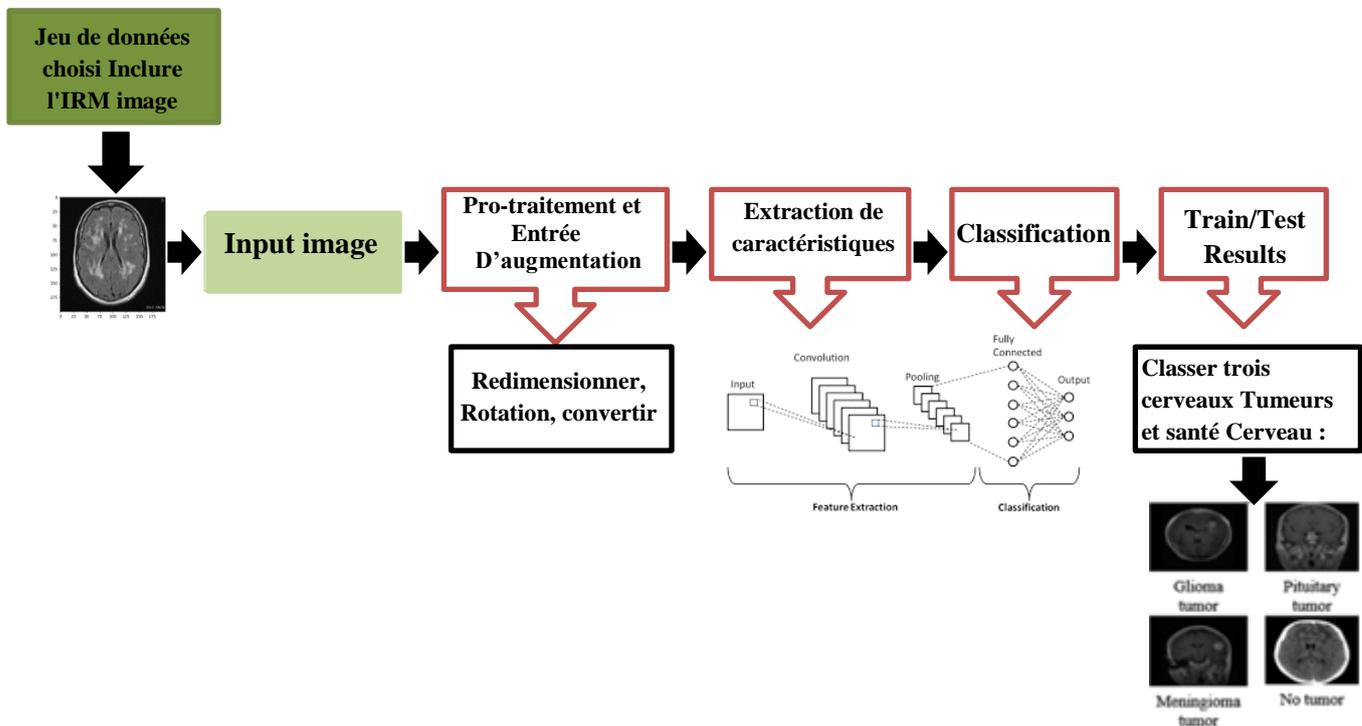


Figure IV.7 : Architecture globale du Modèle proposé.

4.1. Description du Modèle Inception-ResNet-v2

Inception-ResNet-v2 est une architecture neuronale convolutive qui s'appuie sur la famille d'architectures Inception mais intègre des connexions résiduelles (remplaçant l'étape de concaténation de filtres de l'architecture Inception).

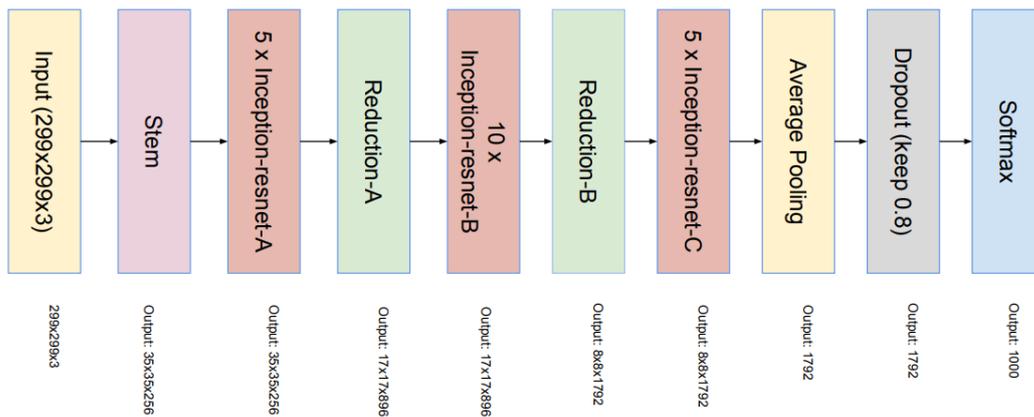


Figure IV.8 : Architecture globale de l'Inception-ResNet-v2 .

4.2. Acquisition de la base de données

Dans le dossier qui contient des données IRM, les images sont déjà divisées en sous-dossiers de formation (Training) et de test (Testing). Chaque dossier a plus de quatre sous-dossiers selon les classes de tumeurs IRM respectives.

- (0) gliome_tumeur : 100 fichiers
- (1) méningiome_tumeur : 115 fichiers
- (2) pas de tumeur : 105 fichiers
- (3) tumeur_hypophysaire : 74 fichiers

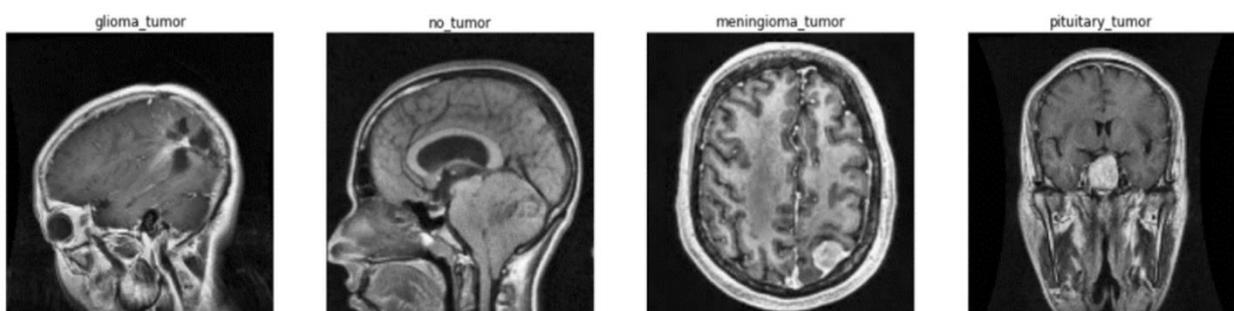


Figure IV.9 : type des tumeurs.

4.3. Importance de la taille du lot (Batch)

De nombreux hyperparamètres doivent être réglés pour disposer d'un réseau neuronal convolutif robuste qui sera capable de classer avec précision les images. L'un des hyperparamètres les plus importants est la taille du lot, qui correspond au nombre d'images utilisées pour former une seule passe avant et arrière. Il peut s'agir de l'une des étapes cruciales pour s'assurer que les modèles atteignent des performances optimales.

En fait, malgré l'importance de la valeur de la taille du lot pour le processus d'apprentissage d'un CNN, la littérature scientifique ne fournit que peu d'études sur ce sujet. De plus, les résultats rapportés dans la littérature ne rapportent pas de conclusions unanimes, certains auteurs indiquant une préférence pour les grandes valeurs de taille de lot et d'autres travaux suggérant l'utilisation de petites valeurs de taille de lot avec différents types d'optimisation (Adam et SGD).

Dans cette étude, l'effet de la taille des lots sur les performances des réseaux de neurones convolutifs et l'impact du type d'optimizer seront étudiés pour la classification d'images.

Les tailles de lots qui seront utilisées dans cette expérience sont = [32, 64, 256] ; les optimiseurs Adam et SGD seront utilisés avec un taux d'apprentissage variable. Pour des raisons de cohérence des résultats et en raison de la taille de l'ensemble de données, le nombre d'époques a été fixé à 20 époques. Pour surmonter le surajustement, seul le meilleur modèle a été enregistré, ce qui signifie que pendant la phase d'entraînement, si l'exactitude (accuracy) de validation de l'époque est supérieure à la précision la plus élevée, le modèle serait enregistré. Les résultats de l'ensemble sont présentés dans les tableaux suivant.

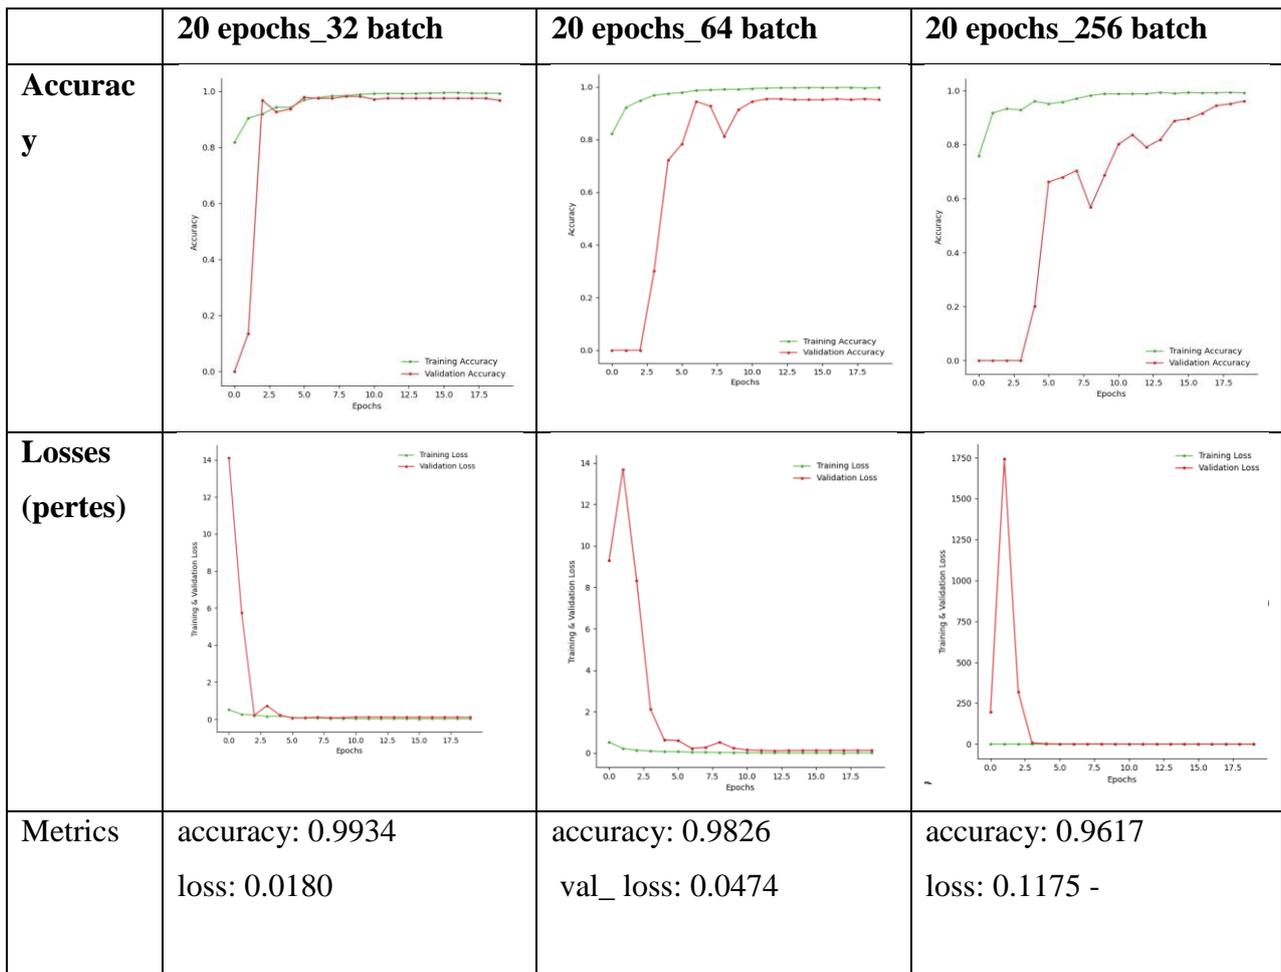


Figure IV.10 : Graphique représentant la précision et la perte de modèle Inception ResNet v2 pour l'ensemble d'entraînement et de validation pour 20 epochs.

À partir des graphiques de précision et de perte du modèle ci-dessus on peut conclure que dans le cas de 64 batchs et 256 batchs, le graphique est désordonné et que la différence entre la perte et la précision est très élevée. Ainsi, leurs valeurs de précision est inférieure à celle de 32 batchs.

Le modèle 32 batchs nous donne un résultat meilleur.

4.4. Métriques d'évaluation des performances

Dans le domaine de l'intelligence artificielle, une matrice de confusion est une matrice dans laquelle la performance des algorithmes pertinents est visualisée. Chaque colonne de la matrice représente la valeur prédite des instances et chaque ligne représente la valeur réelle (vraie) des instances. Cette matrice justifie son appellation qui permet de voir s'il y a des résultats confus ou des chevauchements entre les classes. Dans la recherche médicale, il est très important de réduire les résultats faux positifs et faux négatifs dans le processus de modélisation.

L'objectif principal de l'étude actuelle est de classer les images IRM en classes de gliome, de méningiome, de tumeur de l'hypophyse et de cerveau sain. Les paramètres d'évaluation des performances comprennent l'exactitude, la précision, le rappel et la mesure F.

La précision fait référence à la proximité d'une valeur mesurée par rapport à une valeur standard ou réelle. En d'autres termes, c'est la capacité de l'outil à mesurer la valeur exacte, dont la précision peut être mesurée.

La courbe ROC est construit en traçant le taux de vrais positifs (TPR) par rapport au taux de faux positifs (FPR) dans divers ensembles de seuils. Par conséquent, maximiser le TPR tout en minimisant le FPR sont des réalisations idéales. Cela signifie que le coin supérieur gauche du graphique est le point idéal (FPR = 0 et TPR = 1).

4.5. Résultats obtenus

Comparaison entre l'optimyzer ADAM et SGD pour 32 batches.

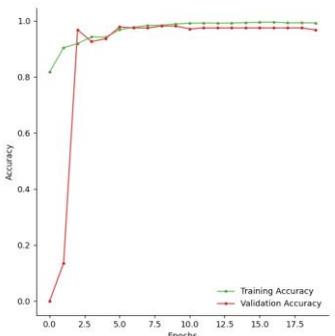
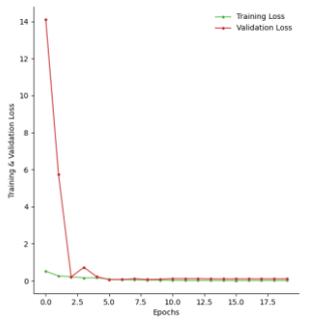
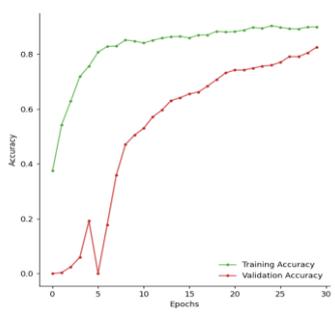
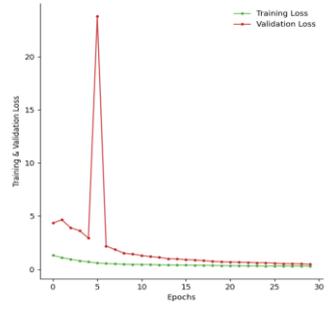
Optimize r	Accuracy	Losses	Matrice de confusion																									
Adam 20 epochs			<p>On Train Set</p> <table border="1"> <tr> <td>glioma</td> <td>0.99</td> <td>0.0061</td> <td>0</td> <td>0.0061</td> </tr> <tr> <td>meningioma</td> <td>0.0049</td> <td>0.98</td> <td>0.0036</td> <td>0.015</td> </tr> <tr> <td>no_tumor</td> <td>0</td> <td>0</td> <td>0.99</td> <td>0.0076</td> </tr> <tr> <td>pituitary</td> <td>0.0024</td> <td>0.0024</td> <td>0.0036</td> <td>0.99</td> </tr> <tr> <td></td> <td>glioma</td> <td>meningioma</td> <td>no_tumor</td> <td>pituitary</td> </tr> </table>	glioma	0.99	0.0061	0	0.0061	meningioma	0.0049	0.98	0.0036	0.015	no_tumor	0	0	0.99	0.0076	pituitary	0.0024	0.0024	0.0036	0.99		glioma	meningioma	no_tumor	pituitary
glioma	0.99	0.0061	0	0.0061																								
meningioma	0.0049	0.98	0.0036	0.015																								
no_tumor	0	0	0.99	0.0076																								
pituitary	0.0024	0.0024	0.0036	0.99																								
	glioma	meningioma	no_tumor	pituitary																								
SGD 30 epochs			<p>On Train Set</p> <table border="1"> <tr> <td>glioma</td> <td>0.95</td> <td>0.034</td> <td>0</td> <td>0.013</td> </tr> <tr> <td>meningioma</td> <td>0.074</td> <td>0.86</td> <td>0.011</td> <td>0.05</td> </tr> <tr> <td>no_tumor</td> <td>0.035</td> <td>0.046</td> <td>0.85</td> <td>0.068</td> </tr> <tr> <td>pituitary</td> <td>0.031</td> <td>0.065</td> <td>0.0036</td> <td>0.9</td> </tr> <tr> <td></td> <td>glioma</td> <td>meningioma</td> <td>no_tumor</td> <td>pituitary</td> </tr> </table>	glioma	0.95	0.034	0	0.013	meningioma	0.074	0.86	0.011	0.05	no_tumor	0.035	0.046	0.85	0.068	pituitary	0.031	0.065	0.0036	0.9		glioma	meningioma	no_tumor	pituitary
glioma	0.95	0.034	0	0.013																								
meningioma	0.074	0.86	0.011	0.05																								
no_tumor	0.035	0.046	0.85	0.068																								
pituitary	0.031	0.065	0.0036	0.9																								
	glioma	meningioma	no_tumor	pituitary																								
Metrics	accuracy: 0.9934 loss: 0.0180	accuracy: 0.9826 val_loss: 0.0474	accuracy: 0.9617 loss: 0.1175 -																									

Figure IV.11 : comparaison des optimisations Adam et SGD.

Un meilleur résultat est obtenu au cours des expériences par l'Adam avec un taux d'apprentissage variable et une taille de lot de 32.

4.6. Analyse et Discussion

Dans cette section, nous allons analyser les performances du modèle proposé. Le modèle proposé est évalué sur différents paramètres. Ces paramètres sont effectués pour déterminer si le modèle proposé est meilleur que les méthodes précédentes et s'il est approprié ou non pour la détection des tumeurs cérébrales. Dans cette étude, nous avons proposé un modèle pour diagnostiquer les tumeurs cérébrales multi classes (méningiome, gliome, sans tumeur et hypophyse).

Classe de tumeur	TP	TN	FP	FN	Précision	Accuracy	Rappel	Score F1	FPR	TNR
Méningiome	0.98	3	0.0085	0.0235	99.1%	99.2%	97.6%	0.983	0.0084	0.997
Gliome	0.99	2.992	0.0073	0.0122	99.2%	99.5%	98.7%	0.989	0.0072	0.997
Pituitaire	0.99	2.974	0.0287	0.0084	97.1%	99.07%	99.1%	0.980	0.0287	0.990
Sans tumeur	0.99	2.996	0.0072	0.0007	99.27	99.63	99.23%	0.992	0.0072	0.997
	Score moyen				98.83%	99.36%	98.81%	0.988	0,0109	0,995

Les résultats obtenus sont présentés dans le tableau suivant pour 20 epochs_32 batchs :

Tableau IV.1 : Analyse : évaluation spécifique à la classe d'une tumeur cérébrale.

Différentes mesures de performance, telles que l'exactitude, la précision, le rappel et le score F1, ont été utilisées pour comparer les performances du modèle suggéré. Ces paramètres sont évalués à l'aide de la matrice de confusion. Les détails ont également été examinés à l'aide de la matrice de confusion illustrée dans la figure suivante.

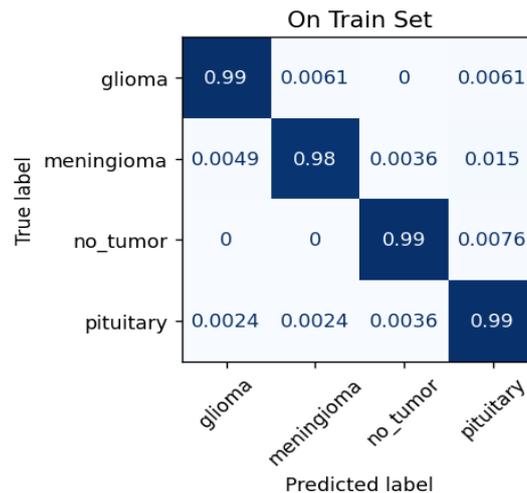


Figure IV.12 : Matrice de confusion pour 20 epochs et 32 batches.

Pour comparer les différentes techniques, trois mesures importantes ont été prises en compte : la précision, le rappel et le score F1. Toutes ces mesures sont basées sur les paramètres suivants

- Vrai positif (**TP**) : également connu sous le nom de **sensibilité**, TP signifie qu'une prédiction positive a été donnée et qu'elle était vraie.
- Vrai négatif (**TN**) : également connu sous le nom de **spécificité**, TN signifie qu'une prédiction négative a été donnée et qu'elle était vraie.
- Faux positif (**FP**) : également connu sous le nom d'erreur de type I, une prédiction FP est positive, mais la valeur réelle était négative.
- Faux négatif (**FN**) : également connu sous le nom d'erreur de type II, une prédiction FN est négative, mais la valeur réelle était positive.

Ainsi pour le gliome : 99% des échantillons ont été classe positive qui sont vrais et ($0.0061+0.0061 = 0.0122 = FN$) n'appartiennent pas à cette class mais sont prédits gliome. Alors que ($0.0049+0.0024 = 0.0073 = FP$) appartiennent à cette classe mais prédits non gliome.

- **Le taux de précision** de la classification mesure la fréquence à laquelle le modèle effectue une prédiction correcte.
- **le taux de mauvaise classification**. Également appelé taux d'erreur, décrit la fréquence à laquelle le classifieur produit de mauvaises prédictions.

- **Valeur de rappel.** le taux de vrais positifs correspond aux observations réelles qui sont prédites correctement.
- **La précision** définit le nombre réel de valeurs correctement prédites qui se sont avérées positives.
- **Le score F** mesure la précision et le rappel en même temps.

Il ressort du tableau et du graphique d'analyse de la figure 10 que la précision, le rappel et le score F1 du **sans tumeur** sont les plus élevés par rapport aux trois autres modèles. La catégorie sans tumeur a les meilleures performances dans toutes les mesures par rapport aux autres types de tumeurs.

Néanmoins, les performances de la tumeur Gliome reste très proche du **sans tumeur** mais avec un TNR supérieur de 0.997, c'est-à-dire que les tumeurs des autres catégories ont été reconnus comme n'étant pas Gliome à 99,7%.

Les performances de la tumeur Pituitaire sont les plus faibles. Ceci est due à cause du FPR = 0.0287, ce qui est relativement élevé, 2,87% des images appartenant à d'autres catégories ont été reconnues comme Pituitaire alors qu'ils ne le sont pas.

Le Méningiome est très proche du Gliome, mais avec un TN = 3, ce qui est meilleur que les autres catégories, c'est à dire que le Méningiome a pu reconnaître les tumeurs qui ne sont pas de sa catégorie mieux que les autres.

Les résultats globaux sont excellents. L'exactitude, la précision, rappel et le score F1 de la méthode proposée sont respectivement de 99.36%, 98.83%, 98.81% et 0.995, ce qui est meilleur que les autres méthodes de comparaison comme la montre le tableau 1.

4.7. Comparaison avec d'autres Travaux de la Littérature

De nombreux chercheurs ont proposé des méthodes et des techniques dans l'apprentissage automatique à l'aide d'une norme accessible aux publics ensembles de données pour les tâches de classification par IRM cérébrale. Le tableau IV.2 représente la comparaison de notre modèle avec d'autres travaux de l'état de l'art existants trouvés dans la littérature. Il ressort de Tableau que notre architecture proposée démontre les meilleures performances de prédiction pour l'identification des tumeurs cérébrales multi classes par rapport aux autres méthodes trouvées dans la littérature avec une base de données relativement moindre.

Méthode	Nombre d'images	Classificateur	Type de classement	Précision
Emra et al. [33]	3064	CNN	Multi classe	92,6
Abiwinanda et al. [34]	700	CNN	Multi Classe	84.1
Sultan et al. [35]	3064	CNN	Multi Classe	96.1
Méthode proposée	394	CNN	Multi classe	98.83

Tableau IV.2 : comparaison de notre modèle avec d'autres travaux de l'état de l'art existants trouvés dans la littérature

5. Travaux futurs

Une limitation de la classification des images médicales est la petite taille des bases de données d'images médicales. Cette limitation, à son tour, limite la disponibilité des images médicales pour la formation des réseaux de neurones profonds. Une façon de relever ce défi dans notre étude consiste à appliquer des techniques d'augmentation des données pour créer de nouvelles lésions tumorales cérébrales par mise à l'échelle et rotation, ce qui peut entraîner un déséquilibre de classe. De plus, dans cette étude, notre projet principal était d'entraîner les réseaux à l'aide d'images locales d'un hôpital, mais le problème d'étiquetage des images a empêché sa mise en œuvre. L'étiquetage des images de cancer prend non seulement du temps, mais nécessite également un haut niveau d'expertise, ce qui est difficile dans l'analyse des tumeurs cérébrales. Dans les travaux futurs, compte tenu de l'importance d'un diagnostic rapide et précis des tumeurs cérébrales sans latence, nous étudierons les constructions d'autres réseaux de neurones profonds robustes pour la classification des tumeurs cérébrales avec moins de temps d'exécution et plus de simplicité. Par conséquent, des algorithmes d'apprentissage automatique complet et d'apprentissage en profondeur peuvent être mis en œuvre en tant qu'améliorations futures. De plus, les techniques proposées peuvent être utilisées pour détecter différentes formes de cancers en IRM ou en tomographie assistée par ordinateur (TDM).

6. Conclusions

Dans notre étude, deux modèles d'apprentissage en profondeur ont été développés pour la détection des tumeurs cérébrales.

L'architecture CNN pour la détection de la présence ou non de la tumeur, tandis que l'architecture "CNN à réglage fin avec InceptionResNet V2" est conçue pour la classification du type de tumeurs. Une technique complète d'augmentation des données est également menée pour améliorer les performances du modèle. Nos résultats expérimentaux ont démontré que notre modèle améliore les performances de prédiction du diagnostic des tumeurs cérébrales. Nous avons atteint une précision de prédiction de 99% surpassant respectivement les études précédentes trouvées dans la littérature. La technique suggérée surpasse les méthodes d'apprentissage en profondeur existantes en termes d'exactitude, de précision et de score F1. Cette idée proposée peut jouer un rôle pronostique dans la détection des tumeurs dans le cerveau.

Nous avons aussi démontré que Le modèle avec 32 batch donne un meilleur résultat que pour un nombre de batch plus élevés et que l'optimizer ADAM serait meilleur que l'optimizer SGD.

Nos recherches futures se concentreront sur la minimisation du nombre de paramètres et du temps de calcul requis pour exécuter le modèle suggéré sans sacrifier les performances.

Conclusion

Générale

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

Durant notre étude sur le domaine de Deep Learning, et l'imagerie médicale :

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

Notre projet a été conçu comme suit :

- Un aperçu sur l'intelligence artificielle, ce domaine qui nous a permis éventuellement de découvrir la possibilité d'implémenter des systèmes artificiels intelligents pouvant réaliser des tâches humaines.
- Une étude détaillée sur la tumeur cérébrale et l'imagerie par résonance magnétique (IRM).
- Une étude brève sur les réseaux de neurones artificiels.
- Nous avons illustré en détails toute notion concernant l'apprentissage profond (Deep Learning), et les réseaux de neurones convolutifs CNN.
- Une conception approfondie où nous avons expliqué les différents sous-systèmes constituant notre projet, ainsi que le prétraitement des images IRM, la construction du modèle de réseau de neurone convolutif, vu sa nécessité dans la résolution de notre problématique.
- En dernier, nous avons détaillé l'implémentation de notre système en représentant les différentes structures de données ainsi que les fonctions employées dans notre logiciel.

En bref, Cette recherche présente deux modèles d'apprentissage en profondeur pour identifier les anomalies cérébrales ainsi que pour classer différents grades de tumeurs, notamment le méningiome, le gliome et l'hypophyse. L'architecture CNN est conçue pour la classification binaire, tandis que l'architecture "Transfer Learning CNN à réglage fin avec InceptionResNet V2" est conçue pour la classification des types de tumeurs. Une technique complète d'augmentation des données est également menée pour améliorer les performances du modèle. Nos résultats expérimentaux ont démontré que le deux modèle pre-entraîne améliore les performances de prédiction du diagnostic des tumeurs cérébrales.

Conclusion Générale

Donc, nous croyons que nos méthodes proposées sont des candidats exceptionnels pour la détection des tumeurs cérébrales.

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

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

Bibliographe

- [1] <https://www.drbsili.com/tumeurs-cerebrales.php>
- [2] <https://sante.journaldesfemmes.fr/fiches-maladies/2653109-cancer-du-cerveau-tumeurs-cerebrales-symptomes-nom/>
- [3] « Généralités sur les tumeurs », Collège Français des Pathologistes (CoPath).
<https://www.ummt0.dz/dspace/bitstream/handle/ummt0/6581/dekkicheSlimane.pdf?sequence=1&isAllowed=y>
- [4] <https://sante.journaldesfemmes.fr/fiches-maladies/2692275-metastases-au-cerveau-cerebrales-symptomes-irm-scanner-traitement-survie-pronostic/>
- [5] <https://tpelyceblaise.pascalorsay.irm.wordpress.com/2016/04/18/lappareil-irm-standard/>, consulter le 09/09/2021.
- [6] https://www.researchgate.net/figure/Les-sequences-IRM-a-image-ponderee-en-T1-b-image-ponderee-en-T2-c-image_fig5_326176238
- [7] https://www.researchgate.net/figure/Representation-en-coupe-du-cerveau-a-Plans-de-coupe-conventionnels-de-neuroanatomie-et_fig3_278643302
- [8] Dr Maryam Asad-Syed, radiologue, IMAGIR, Bordeaux, Nicole Dispens, patiente Aubergenville, Michel Kauffmann, patient et bénévole du Comité de patients pour la recherche clinique en cancérologie de la Ligue contre le cancer, Pr Alain Luciani radiologue Hôpitaux universitaires, Henri Mondor, Université Paris-Est Créteil, apr.-HP membre du bureau de la Société
- [9] MEZIANE Abdelfettah. Etude et comparaison des méthodes de segmentation d'images cérébrales. Mémoire pour l'obtention du diplôme de Magister en Informatique Option : IAAD (Intelligence Artificielle et Aide à la Décision). Université Abou-Bakr BelkaidTlemcen. 07-2011.
- [10] <http://dspace.univ-telemcen.dz/bitstream/112/375/1/etude-et-comparaison-des-methodes-de-segmentation-dimages-cerebrales.pdf>
- [11] <https://fourweekmba.com/fr/apprentissage-en-profondeur-vs-apprentissage-automatique/>.
- [12] Machine learning, deep learning : quelles différences ?
<https://siecdigital.fr/2019/01/30/differences-intelligence-artificielle-machinelearning-deep-learning/> (accessed May 28, 2021).
- [13] A History of Machine Learning and Deep Learning | Import.io.
<https://www.import.io/post/history-of-deep-learning/> (accessed May 30, 2021).

- [14] Apprentissage automatique et Apprentissage profond | STEMMER IMAGING. <https://www.stemmer-imaging.com/fr-ch/conseil-technique/apprentissage-automatique-et-apprentissage-profond/> (accessed May 28, 2021).
- [15] <https://blent.ai/reseaux-de-neurones-tout-comprendre/>.
- [16] D. Nene, A. Dian, and K. M. Nadjib, —Mémoire de Fin d ' études Master La reconnaissance des expressions faciales, 2019.
- [17] <https://openclassrooms.com/fr/courses/4470406-utilisez-des-modeles-supervises-non-lineaires/4730716-entraenez-un-reseau-de-neurones-simple>.
- [18] Deep Learning ou apprentissage profond : définition, concept.
- [19] <https://www.lebigdata.fr/deep-learning-definition> (accessed May 30, 2021).
- [20] MINISTÈRE DE L'ENSEIGNEMENT SUPÉRIEUR ET DE LA RECHERCHE SCIENTIFIQUE Université Mouloud Mammeri de Tizi-ouzou.
- [21] Comprendre le DEEP LEARNING - une introduction aux réseaux de neurones de Jean-Claude Heudin-201710121430.pdf.
- [22] D. Bouadi, —Thème : Classification d ' images agricoles avec le Deep Learning Réalisé par : Encadré par : Mme Rachida AOUDJIT Tables des matières : Chapitre 2 : Deep Learning , Machine Learning et Réseaux de neurones et, 2019.
- [23] <https://moncoachdata.com/blog/comprendre-les-reseaux-de-neurones/>.
- [24] <https://www.aspexit.com/reseau-de-neurones-on-va-essayer-de-demystifier-un-peu-tout-ca-1/>.
- [25] Y. D. Moualek, —Deep Learning pour la classification des images, pp. 2016–2017, 2017.
- [26] <https://france.devoteam.com/paroles-dexperts/aller-plus-loin-en-deep-learning-avec-les-reseaux-de-neurones-recurrents-rnns/>.
- [27] D. E. Rumelhart, G. E. Hinton, and R. J. Williams. Learning internal representations by error propagation. In *Parallel distributed processing: Explorations in the microstructure of cognition*, Volume 1: Foundations. MIT Press, 1986.
- [28] Houacine Noura, Khelifa Nadia, Classification des textures par les réseaux de neurones convolutif, thèse MASTER ACADEMIQUE, Domaine : Sciences et Technologies, Filière : Génie électrique, Spécialité : Commande des systèmes, faculté du genie électrique et d'informatique département d'automatique, université mouloud mammeri de tizi-ouzou, 27/09/2018.
- [29] Qu'est ce qu'un réseau de neurones convolutif (ou CNN) ? - Classez et segmentez des données visuelles – Open Classrooms. <https://openclassrooms.com/fr/courses/4470531->

classez-et-segmentez-des-donnees-visuelles/5082166-quest-ce-quun-reseau-deneurones-convolutif-ou-cnn (accessed May 28, 2021).

[30] S. Ravichandiran, Hands-On Deep Learning. 2019.

[31] <https://stanford.edu/~shervine/l/fr/teaching/cs-230/pense-bete-reseaux-neurones-convolutionnels>

[32] <https://www.pinecone.io/learn/transfer-learning/>

[33] Irmak E. Multi-classification des images IRM de tumeurs cérébrales à l'aide d'un réseau de neurones à convolution profonde avec un cadre entièrement optimisé. Iran J Sci Technol Trans Electr Eng. 2021 ; 45 (3):1015–1036.

[34] Abiwinanda N, Hanif M, Hesaputra ST, Handayani A, Mengko TR. Classification des tumeurs cérébrales à l'aide d'un réseau de neurones convolutifs. In World congress on medical physics and biomedical engineering 2018 2019 (pp. 183-189).

[35] Sultan HH, Salem NM, Al-Atabany W. Multi-classification des images de tumeurs cérébrales à l'aide d'un réseau de neurones profonds. Accès IEEE. 2019 ; 7 :69215–69225.