

الجمهورية الجزائرية الديمقراطية الشعبية
République Algérienne démocratique et populaire

وزارة التعليم العالي و البحث العلمي
Ministère de l'enseignement supérieur et de la recherche
scientifique

جامعة سعد دحلب البليدة
Université SAAD DAHLAB de BLIDA

كلية التكنولوجيا
Faculté de Technologie

قسم الإلكترونيك
Département d'Électronique



Mémoire de fin d'étude

Filière : Télécommunications

Spécialité : Réseaux et télécommunications

Présenté par :

MEDJEROUB Assala Chaimaa

et

SALMI Abdelkader Ramzi

Theme:

**Classification d'IRM lombaires par Deep Learning pour le diagnostic de la
lordose**

Proposé par : Pr BENBLIDIA Nadja

Et M.LAAZAB Kheira

Année Universitaire 2023-2024

Je dédie ce mémoire de recherche :

A ma très chère mère

Même si tu n'es plus là, ton souvenir et ton amour me guident chaque jour. Tu es et tu resteras à jamais mon inspiration et ma force.

A mon cher père

Aucun remerciement ne saurait exprimer l'amour, l'estime, le dévouement et le respect que j'ai toujours eu pour toi. Que Dieu te préserve et t'accorde santé, longue vie et bonheur.

A ma chère sœur et mes chers frères

A ma sœur MANEL, mes frères ABDERRAOUF , SEIFEDDINE et DHIAE EDDINE, Vous êtes toujours dans mon cœur. Je vous remercie d'être l'épaule sur laquelle je peux toujours compter.

À mon neveu Ryan, notre petit prince de la famille.

A mon binôme Ramzi

Merci pour ta complicité et ton énergie débordante. Ton aide a été un pilier sur lequel je me suis appuyé sans hésitation .

Et a tout mon entourage,

Assala

Remerciements

Nous tenons avant tout à exprimer notre profonde gratitude à ALLAH le Bienveillant, qui nous a donné la force, la santé et la persévérance nécessaires pour réussir ce projet.

Nous voudrions ensuite exprimer notre profonde reconnaissance à notre promotrice, Mme BENBLIDIA Nadjia, pour son encadrement précieux et ses conseils avisés tout au long de ce parcours.

Nous remercions également Mme LAAZAB Kheira, notre co-promotrice, pour son soutien, sa disponibilité et ses encouragements qui nous ont permis de progresser et de nous surpasser.

Nous tenons à remercier M. AIT SAADI Houcine, chef de département. Ses conseils et sa bienveillance ont été une source de motivation constante.

Nous remercions les membres du jury, Mme REGUIEG F. Zohra et M. BENYAHIA, pour avoir accepté d'évaluer ce mémoire et pour leurs remarques constructives qui nous permettront de l'améliorer.

Nous exprimons notre profonde gratitude à notre famille, pilier de soutien indéfectible tout au long de notre parcours. Leur amour inconditionnel, leurs encouragements constants ont été notre force motrice.

Enfin, nous souhaitons adresser un remerciement spécial à notre amie CAID Racim pour son aide précieuse. Son soutien et sa présence nous ont été d'un grand secours.

ملخص: يهدف هذا المشروع إلى تطوير نموذج تعلم عميق لتشخيص دقيق لأمراض العمود الفقري، الذي يلعب دورًا أساسيًا في الدعم البدني وحماية النخاع الشوكي. باستخدام مجموعة بيانات صور الرنين المغناطيسي للعمود الفقري التي ، قمنا (MRI) تحتوي على 514 صورة للعمود الفقري تم الحصول عليها عن طريق التصوير بالرنين المغناطيسي تشير النتائج إلى أن نموذجنا DenseNet و ResNet ، VGG19 ، VGG16 بتدريب وتقييم عدة نماذج بما في ذلك F1 ، يظهر فعالية عالية في سياق تصنيف أمراض العمود الفقري القطني، مع درجة DetecLordose الخاص، المسمى تبلغ 93%.

كلمات المفاتيح: التعلم العميق، تشخيص امراض العمود الفقري، التصوير بالرنين المغناطيسي،

vgg16 ، Vgg19 ، Resnet18 ، Resnet 34 Densnet121 ، التصنيف ، DetecLordose

Résumé

Ce projet consiste à développer un modèle de deep learning pour obtenir un diagnostic précis des pathologies de la colonne vertébrale, qui joue un rôle fondamental dans le soutien physique et la protection de la moelle épinière. En utilisant un ensemble de données Spinal MRI Images contenant un total de 514 images de la colonne vertébrale obtenues par résonance magnétique (IRM), nous avons entraîné et évalué plusieurs modèles, notamment VGG16, VGG19, ResNet et DenseNet. Les résultats indiquent que notre propre modèle, appelé DetecLordose, démontre une grande efficacité dans le contexte de la classification des pathologies lombaires, avec un F1-score de 93 %.

Mots clés : Deep learning, diagnostic, pathologies de la colonne vertébrale, IRM, VGG16, VGG19, ResNet 18 , Resnet 34, DenseNet 121 , classification, DetecLordose, Précision

Abstract : This project aims to develop a deep learning model for accurately diagnosing spinal pathologies, which play a fundamental role in physical support and spinal cord protection. Using a dataset of Spinal MRI Images containing a total of 514 spinal images obtained through magnetic resonance imaging (MRI), we trained and evaluated several models, including VGG16, VGG19, ResNet, and DenseNet. The results indicate that our own model, called DetecLordose, demonstrates high effectiveness in the context of lumbar pathology classification, with an F1-score of 93%.

Keywords : Deep learning, diagnostic, pathologies de la colonne vertébrale, IRM, VGG16, VGG19, ResNet18 , Resnet 34 , DenseNet 121 , classification, DetecLordose, Accuracy

Table Des Matières		
Introduction Générale		02
Chapitre I. Contexte Médical		
I.1. Introduction		04
I.2. Rachis (Colonne Vertébrale)		04
I.2.1. Anatomie du rachis		05
I.2.2. Fonctions du rachis		08
I.2.3. Rôle du rachis		09
I.3. Pathologies Lombaires		09
I.3.1. Généralités sur les pathologies lombaires		09
I.3.2. Scoliose		10
I.3.3. Hernie Discale		10
I.3.4. Lordose		11
I.3.5. Impact des pathologies lombaires sur la qualité de vie		13
I.4. Système d'Acquisition		14
I.4.1. Imagerie par résonance magnétique (IRM)		14
I.4.2. Scanner (Tomodensitométrie)		17
I.4.3. Radiographie		19
I.4.4. Echographie		20
I.5. Conclusion		21
Chapitre II. Apprentissage Automatique et Profond		
II.1. Introduction		23
II.2. Apprentissage automatique		23
II.2.1. Définition du machine learning		23
II.2.2. Principe du machine learning		24
II.2.3. Méthode d'apprentissage automatique		24
II.3. Apprentissage profond		28
II.3.1. Définition du Deep Learning		28
II.3.2. Principe du Deep Learning		29
II.3.3. Le processus d'apprentissage dans le Deep Learning		29
II.3.4. Application du Deep Learning dans le domaine médical		31
II.4. Réseaux de Neurones		31
II.4.1. Qu'est ce qu'un réseau neuronal		31
II.4.2. Architecture d'un neuronal simple		32
II.4.3. Architecture d'un réseau neuronal profond		34
II.4.4. Les types des réseaux neuronaux		35
II.4.5. Architecture des CNN		36
II.4.6. Fonctionnalités des CNN dans la classification d'images		38
II.5. Conclusion		40
Chapitre III. Modèles de classification pour l'apprentissage par transfert		

Table des matières

III.1. Introduction	42
III.2. Un bref parcours des travaux de classification spinale	42
III.3. Modèle d'entraînement explorés	45
III.3.1.VGG16 (Visual Geometry Group 16-Layer)	46
III.3.2.VGG19 (Visual Geometry Group 19-Layer)	46
III.3.3.ResNet18 (Residual Network 18-Layer)	47
III.3.4.ResNet34 (Residual Network 34-Layer)	47
III.3.5.DenseNet121 (Densely Connected Convolutionnal Network 121-Layer) ...	48
III.4. Métriques d'évaluation	48
III.4.1.Matrice de confusion	48
III.4.2.Critères d'évaluation	49
III.5. Conclusion	50
Chapitre IV. Développement et Évaluation Comparative du Système	
IV.1. Introduction	52
IV.2. Environnement de travail	52
IV.2.1. Hardware	52
IV.2.2. Software	52
IV.2.3. Bibliothèques utilisées	53
IV.3. Architecture générale du système de classification 'DetecLordose'	54
IV.3.1. Description du Dataset	55
IV.3.2. L'angle de Cobb et Méthodologie de calcul	55
IV.3.3. Catégorisation des données	57
IV.3.4. Prétraitement des données	58
IV.3.5. Modèle 'Deteclordose'	60
IV.4. Résultats	63
IV.4.1. Résultats du modèle DenseNet 121	63
IV.4.2. Résultats du modèle VGG 19	65
IV.4.3. Résultats du modèle VGG 16	67
IV.4.4. Résultats du modèle 'Deteclordose'	69
IV.5. Comparaison et discussion	70
IV.5.1. Comparaison des résultats	70
IV.5.2. Discussion	70
IV.6. Conclusion	72
Conclusion Générale	74
Bibliographie	76

Listes des acronymes et abréviations

ADAM : Adaptive Moment Estimation

CNN : Convolutional Neural Network

DenseNet121 : Densely Connected Convolutional Networks 121-layer

DL : Deep Learning

FN : False Negative

FP : False Positive

FC : Fully Connected

IA : Intelligence Artificielle

IRM : Imagerie par Résonance Magnétique

K-means : K-Means Clustering

KNN : K-Nearest Neighbors

ML : Machine Learning

ReLU : Rectified Linear Unit

ResNET18 : Residual Network 18-layer

RESNET34 : Residual Network 34-layer

RNA : Réseaux de Neurones Artificiels

RNN : Recurrent Neural Network

SVM : Support Vector Machine

TDM : Tomodensitométrie

TN : True Negative

TP : True Positive

VGG16 : Visual Geometry Group 16-layer network

VGG19 : Visual Geometry Group 19-layer network

Liste des Figures

Chapitre I. Contexte Médical

Figure I.1. Anatomie de la colonne vertébrale	4
Figure I.2. Vertèbres cervicale	5
Figure I.3. Vertèbres thoraciques	6
Figure I.4. Vertèbres lombaire	6
Figure I.5. Anatomie du sacrum + le coccyx	6
Figure I.6. Disque Intervertébrale	7
Figure I.7. Les ligamments intervertébraux	7
Figure I.8. Les muscles verébraux	8
Figure I.9. La colonne vertébrale et le système nerveux	8
Figure I.10. Une radiographie d'une scoliose.....	10
Figure I.11. Une radiographie d'une hernie discale	11
Figure I.12. Comparaison des radiographies d'une colonne vertébrale normale, d'une cyphose et d'une lordose	12
Figure I.13. Une hyperlordose	12
Figure I.14. Une hypolordose	13
Figure I.15. Un appareil d'imagerie par résonance magnétique (IRM)	15
Figure I.16. Ordinateur de controle de salle IRM	16
Figure I.17. Un appareil de scanner médical	18
Figure I.18. Un appareil de radiographie	20
Figure I.19. Un appareil d'échographie	21

Chapitre II. Apprentissage Automatique et Profond

Figure II.1. Les catégories d'apprentissage automatique	26
Figure II.2. Apprentissage supervisé	27
Figure II.3. Algorithme d'apprentissage automatique supervisée.....	27
Figure II.4. Apprentissage non-supervisé	28
Figure II.5. Algorithme d'apprentissage automatique non supervisée.....	28
Figure II.6. Introduction a l'apprentissage profond	29
Figure II.7. Principe du Deep Learning	30
Figure II.8. Architecture d'un réseau neuronal simple	33
Figure II.9. Architecture d'un réseau neuronal profond	35

Figure II.10. Architecture des CNNs	38
Figure II.11. Opération de max pooling	40
Figure II.12. Opération de min pooling	40

Chapitre III. Modèles de classification pour l'apprentissage par transfert

Figure III.1. Méthodes utilisées pour l'évaluation de la courbe lordotique lombaire	44
Figure III.2. Modèle de vgg16	47
Figure III.3. Modèle de vgg19	47
Figure III.4. Architecture du resnet 18	48
Figure III.5. Architecture du resnet 34	48
Figure III.6. Architecture du densnet 121	49

Chapitre IV. Développement et Évaluation Comparative du Système

Figure IV.1. Schéma générale du système de classification	55
Figure IV.2. Processus de calcul de Cobb angle	57
Figure IV.3. Architectue du modele 'Deteclordose'	62

Liste des Tableaux

Chapitre II. Apprentissage Automatique et Profond

Tableau II.1. Les fonctions d'activation les plus importants des le deep learning..... 34

Chapitre III. Modèles de classification pour l'apprentissage par transfert

Tableau III.1. Tableau qui explique une matrice de confusion 49

Chapitre IV. Développement et Évaluation Comparative du Système

Tableau IV.1. Les techniques d'augmentation de données appliquées aux images 59

Tableau IV.2. Tableau comparatif des performances des modèles 72

Tableau IV.3. Tableau de comparaison détaillée des performances des modèles 73

Introduction Générale

Introduction Générale

La colonne vertébrale, ou rachis, est une structure fondamentale du corps humain, assurant à la fois soutien et protection à la moelle épinière. Les pathologies lombaires, telles que la scoliose, la hernie discale et la lordose, peuvent affecter considérablement la qualité de vie des individus. Le diagnostic et le traitement précis de ces pathologies sont essentiels pour améliorer les résultats cliniques et le bien-être des patients.

L'avènement de l'intelligence artificielle, notamment de l'apprentissage automatique (Machine Learning) et de l'apprentissage profond (Deep Learning), ouvre de nouvelles perspectives pour le diagnostic médical. Ces technologies permettent d'analyser de vastes ensembles de données médicales avec une précision et une efficacité accrues. Les réseaux neuronaux convolutifs (CNN) en particulier ont démontré leur potentiel dans la classification des images médicales, ouvrant la voie à des systèmes de diagnostic assisté par ordinateur.

Le diagnostic des pathologies lombaires reste un défi majeur, notamment en raison de la complexité des images médicales et de la variabilité des symptômes cliniques. Les méthodes traditionnelles, telles que les examens physiques et les radiographies, peuvent parfois manquer de précision ou de sensibilité. De plus, l'interprétation des images médicales par des experts humains peut être sujette à la variabilité interindividuelle.

L'objectif de cette recherche est d'explorer l'utilisation de techniques d'apprentissage non supervisé pour le diagnostic des pathologies lombaires à partir d'images médicales. Nous proposons de développer et d'évaluer un système de diagnostic assisté par ordinateur basé sur l'apprentissage profond, capable de classifier avec précision les images de scoliose, de hernie discale et de lordose.

L'étude se divise en plusieurs chapitres, commençant par une introduction au contexte médical et aux pathologies lombaires. Elle se poursuit par une exploration des principes de l'apprentissage automatique et profond, puis par la présentation des modèles de classification utilisés dans l'apprentissage par transfert. Enfin, le développement et l'évaluation comparative du système 'DetecLordose' sont détaillés, incluant l'environnement de travail, la description des données, les méthodes de prétraitement et les résultats obtenus.

Chapitre I
Contexte Médical

I.1.Introduction :

Dans le domaine médical, le diagnostic précis des pathologies est essentiel pour assurer des traitements efficaces et améliorer la qualité de vie des patients. La colonne vertébrale, ou rachis, est une structure centrale du corps humain, jouant un rôle fondamental dans le soutien physique, la protection de la moelle épinière, et la facilitation des mouvements. Ce chapitre propose une exploration approfondie du rachis, en abordant son anatomie, son fonctionnement, et les principales pathologies lombaires qui peuvent affecter cette structure vitale.

Ce chapitre établit ainsi le cadre médical nécessaire pour comprendre les défis et les opportunités liés à l'application du Deep Learning pour la classification non supervisée d'images dans le diagnostic des pathologies lombaires.

I.2.Le Rachis (Colonne Vertébrale)

La colonne vertébrale ou rachis est une chaîne osseuse articulée, résistante et flexible. Située la partie médiane et postérieure du tronc ,depuis la tête qu'elle soutient jusqu'au bassin qui la supporte .

Elle engaine et protège la moelle spinale contenue dans le canal vertébral . elle se compose d'éléments osseux superposés appelés vertèbres. contient 33 vertèbres chez l'adulte, mais seulement 24 d'entre elles sont des vertèbres mobiles et 9 vertèbres sont fusionnées et ne sont pas mobiles (**Figure I.1 montre l'anatomie de la colonne vertébrale**) [1].



Figure I.2. Anatomie de la colonne vertébrale [2]

I.2.1. Anatomie du rachis

La colonne vertébrale se compose de plusieurs éléments travaillant ensemble pour assurer sa solidité, sa flexibilité et sa fonction protectrice [3].

1. Les vertèbres

Les vertèbres sont les os qui forment la base de la colonne vertébrale. On en compte 33, réparties en cinq régions distinctes :

- **7 vertèbres cervicales (C1 à C7)**: situées dans le cou, elles permettent une grande mobilité de la tête (Figure I.2 montre les vertèbres cervicales).

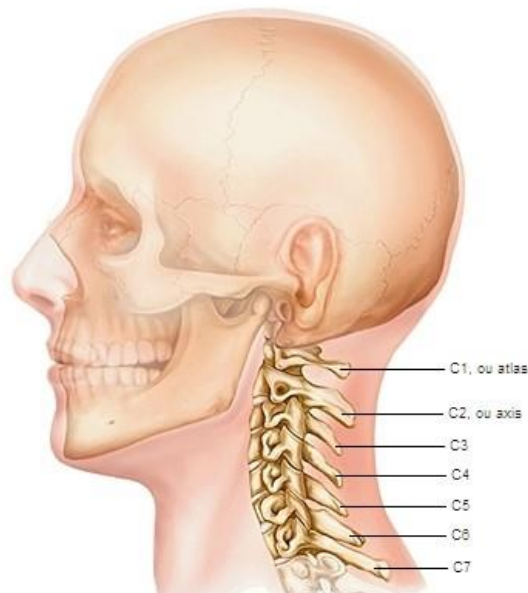


Figure I.3. Vertèbres cervicale [4]

- **12 vertèbres thoraciques (T1 à T12)** : articulées aux côtes, elles protègent les organes de la poitrine (**Figure I.3** montre les Vertèbres thoraciques).




Figure I.4. Vertèbres thoraciques [5]

- **5 vertèbres lombaires (L1 à L5)** : plus massives, elles supportent le poids du haut du corps et assurent la flexion, l'extension et l'inclinaison du tronc



Figure I.5. Vertèbres lombaire [6]

- **5 vertèbres sacrées** : fusionnées en un os unique, le sacrum, elles forment la base de la colonne et s'articulent avec les os du bassin.




Figure I.6. Anatomie du sacrum + le coccyx [7]

- **4 vertèbres coccygiennes:** petites et soudées entre elles, elles constituent le vestige de la queue chez les primates.

2. Les disques intervertébraux

Situés entre chaque vertèbre, les disques intervertébraux jouent un rôle crucial d'amortisseur et de distributeur de charge. Ils sont composés d'un noyau gélatineux entouré d'anneaux fibreux .




Figure I.7. Disque Intervértebrale [8]

3. Les ligaments

Ce sont des supers « scotchs » qui unissent les os les uns aux autres. Ils sont très nombreux dans la colonne unissant fortement les différentes structures entre elles [8].




Figure I.8. Les ligaments intervertébraux [8]

4. Les muscles vertébraux

Ils protègent l'articulation, la soutiennent et en assurent la mobilité. Deux types de muscles sont particulièrement importants pour la colonne : en avant ce sont les abdominaux et en arrière les extenseurs du rachis (spinaux et dorsaux)[3].




Figure I.9. Les muscles verébraux [8]

5. Les nerfs

La moelle épinière, contenue dans le canal rachidien, est formée de nerfs qui transmettent les informations entre le cerveau et le reste du corps. Les racines nerveuses émergent de la moelle épinière à travers les foramens intervertébraux, situés entre les vertèbres[3] .




Figure I.10. La colonne vertébrale et le système nerveux [8]

6. Les vaisseaux

Des artères et des veines irriguent la colonne vertébrale, fournissant aux os, aux muscles et aux nerfs les nutriments et l'oxygène nécessaires à leur fonctionnement.

I.2.2. Fonctions du rachis :

Le rachis remplit plusieurs fonctions essentielles qui sont cruciales pour le maintien de la posture, la mobilité et la protection du système nerveux central. Voici un aperçu de ses principales fonctions [9] :

- **Organe statique** : il supporte le poids du corps. Les contraintes mécaniques augmentent au fur et à mesure qu'on descend la colonne. La totalité est transmise via le sacrum aux ailes iliaques, puis aux deux membres inférieurs par les articulations coxo-fémorales.
- **Organe dynamique** : les vertèbres sont articulées les unes par rapport aux autres, ce qui permet un certain nombre de mouvements qui peuvent être de grande amplitude au niveau cervical (mobilité de la tête) mais moindres au niveau de la cage thoracique. Toute cette mobilisation vertébrale est rendue possible par l'existence de muscles qui vont assurer d'une part la statique et le maintien du rachis et d'autre part la mobilité.
- **Organe de protection** : les vertèbres sont creusées par un canal, cette superposition des vertèbres permet la formation du canal rachidien, qui contient la moelle épinière depuis la première vertèbre cervicale jusqu'au niveau L1/L2. En dessous, c'est la queue de cheval, c'est-à-dire la fin de la moelle épinière.

I.2.3. Rôle du rachis :

Le rachis lombaire, en particulier, joue plusieurs rôles cruciaux pour le bon fonctionnement de la colonne vertébrale et du corps dans son ensemble. Voici un aperçu de ses principales fonctions [10] :

- **Rôle de protection de la moelle épinière** : Comme le reste de la colonne vertébrale, le rachis lombaire protège la moelle épinière jusqu'aux vertèbres L1-L2, puis les nerfs spinaux à partir de L1-L2.
- **Rôles de soutien et de mobilité de la colonne vertébrale** : Sur le plan dynamique, de par sa situation, le rachis lombaire soutient le reste de la colonne vertébrale et assure sa mobilité.
- **Rôle d'amortisseur et de répartition des charges** : Le rachis lombaire joue également le rôle d'amortisseur et de répartition des charges entre le bassin et le thorax. Les muscles érecteurs du rachis, également appelés muscles spinaux, qui s'étendent de part et d'autre du rachis permettent de soulager en partie cette pression exercée sur la colonne vertébrale.

I.3. Pathologies Lombaires :

I.3.1. Généralités sur les pathologies lombaires :

Les pathologies lombaires, plus communément appelées lombalgies, regroupent un large éventail de troubles qui affectent la région lombaire, c'est-à-dire le bas du dos. Elles constituent

l'une des causes majeures de consultation médicale et d'arrêt de travail, touchant une grande partie de la population à un moment donné de leur vie [11].

I.3.2. La Scoliose :

Définition:

La scoliose est une déformation latérale de la colonne vertébrale qui se manifeste par une courbure anormale en forme de "S" ou de "C". Elle touche plus souvent les filles que les garçons et apparaît généralement entre l'âge de 10 et 16 ans [12].



Figure I.11. Une radiographie d'une scoliose [13]

Causes:

La cause exacte de la scoliose est souvent inconnue (idiopathique). Cependant, plusieurs facteurs peuvent y contribuer, tels que :

- Prédilection génétique: Avoir des antécédents familiaux de scoliose augmente le risque de développer la maladie.
- Anomalies congénitales: Certaines malformations des vertèbres ou des côtes peuvent favoriser l'apparition d'une scoliose.
- Neuromusculaires: Des maladies neuromusculaires comme la paralysie cérébrale ou la dystrophie musculaire peuvent également être associées à la scoliose.

I.3.3. L'Hernie Discale

Une hernie discale est la protrusion ou la rupture d'un disque intervertébral, qui se situe entre chaque vertèbre de la colonne vertébrale. Ce disque, composé d'un noyau gélatineux et d'anneaux fibreux, agit comme un amortisseur et permet la mobilité du rachis. Lorsque le disque

se déplace, son contenu peut comprimer les racines nerveuses adjacentes, provoquant une douleur intense [14].

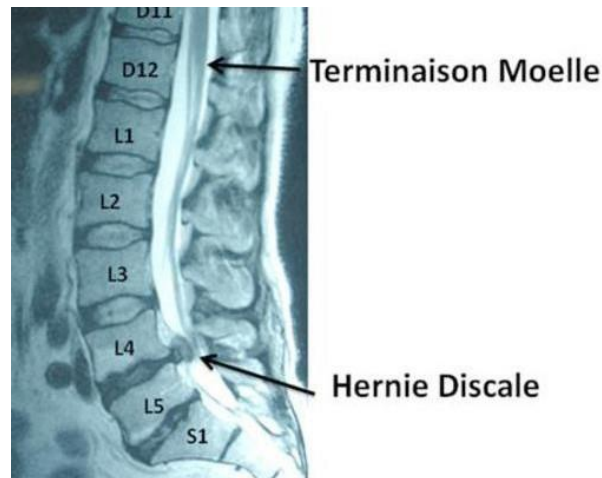


Figure I.12. Une radiographie d'une hernie discale [15]

Causes

Les causes de l'hernie discale sont multiples :

- **Âge:** Le risque d'hernie discale augmente avec l'âge, car les disques intervertébraux s'usent et se détériorent naturellement.
- **Mouvements brusques ou soulèvements de charges lourdes:** Ces actions peuvent exercer une pression excessive sur les disques et favoriser la hernie.
- **Prédisposition génétique:** Certains individus sont plus susceptibles de développer des hernies discales que d'autres.
- **Obésité:** Le surpoids exerce une pression supplémentaire sur la colonne vertébrale et augmente le risque d'hernie discale.

I.3.4. Lordose

La lordose est la courbure naturelle de la colonne vertébrale vers l'intérieur, au niveau du cou (lordose cervicale) et du bas du dos (lordose lombaire). Cette courbure permet à la colonne vertébrale d'absorber les chocs et de maintenir l'équilibre du corps [16].

Il existe deux types de lordose :

- Lordose cervicale : Elle se situe au niveau du cou et permet de maintenir la tête droite.
- Lordose lombaire : Elle se situe au niveau du bas du dos et permet de maintenir la colonne vertébrale arquée.

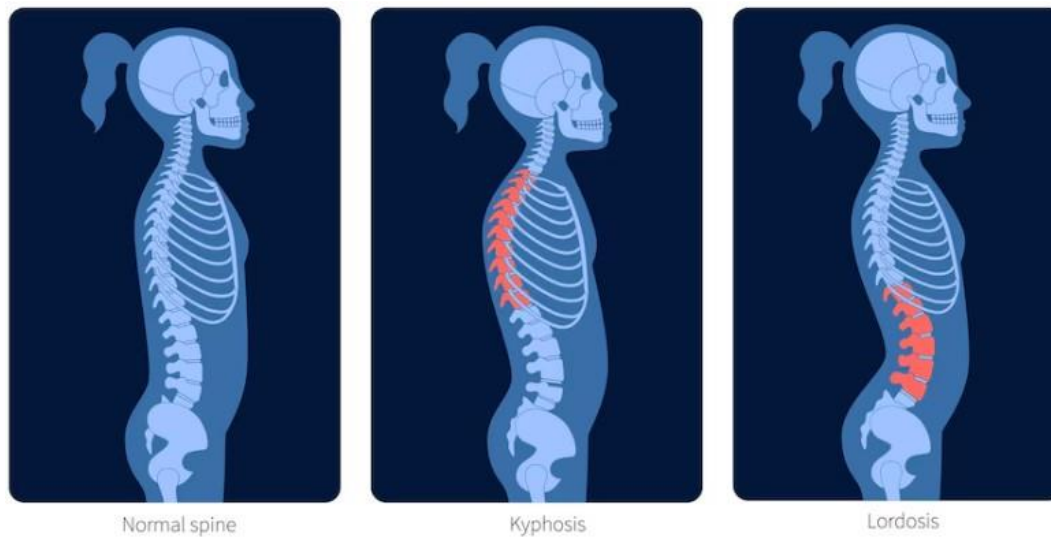


Figure I.13. Comparaison des radiographies d'une colonne vertébrale normale, d'une cyphose et d'une lordose [17]

Cette photo montre une colonne vertébrale normale avec une lordose lombaire (courbure vers l'avant) physiologique.

La lordose est considérée comme normale lorsqu'elle est légère. Cependant, une lordose excessive, appelée hyperlordose

Hyperlordose : L'hyperlordose est une courbure excessive de la colonne vertébrale vers l'avant, au niveau du bas du dos (rachis lombaire). Cette courbure exagérée peut entraîner des douleurs, une raideur et une mauvaise posture[18].

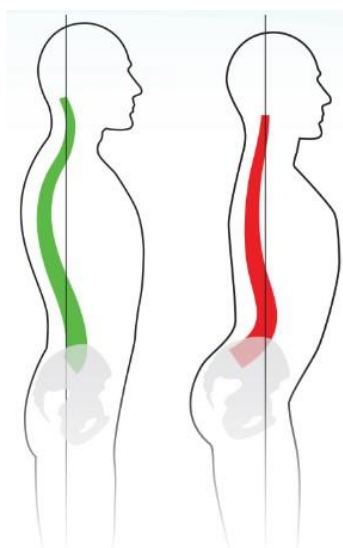


Figure I.14. Une hyperlordose [18]

Sur l'image, on peut voir que la colonne vertébrale avec hyperlordose présente une courbure beaucoup plus prononcée vers l'avant au niveau du bas du dos.

Hypolordose : L'hypolordose est une courbure insuffisante ou inversée de la colonne vertébrale vers l'avant, au niveau du bas du dos (rachis lombaire). Cette courbure aplatie peut entraîner des douleurs, une raideur et une mauvaise posture[18].

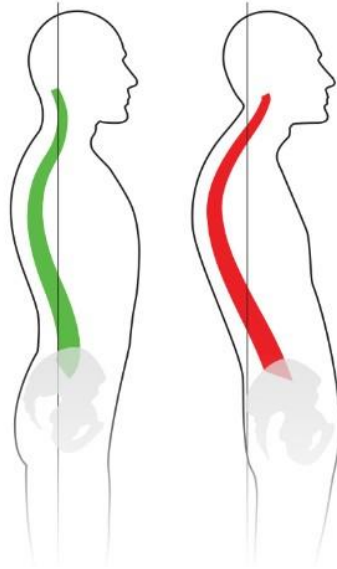


Figure I.15. Une hypolordose [18]

Cette figure montre une colonne vertébrale avec une hypolordose. La courbure vers l'avant du bas du dos est réduite.

Causes

- Mauvaise posture
- Faiblesse musculaire
- Certaines conditions médicales (arthrite, obésité, grossesse)
- Facteurs génétiques

I.3.5. Impact des pathologies lombaires sur la qualité de vie

Les pathologies lombaires, telles que la lombalgie, l'hyperlordose, l'hypolordose et la cyphose, peuvent avoir un impact significatif sur la qualité de vie d'une personne. La douleur lombaire est le symptôme principal de la plupart de ces pathologies et peut être aiguë ou chronique, limitant ainsi la mobilité, la flexibilité et la capacité à effectuer des activités quotidiennes telles que se lever, se baisser, marcher, s'asseoir ou rester debout pendant de longues périodes

(**Douleur et limitation physique**) . L'hyperlordose et l'hypolordose peuvent également causer de la douleur et de la raideur dans le bas du dos, affectant encore davantage la mobilité et la flexibilité. De plus, la cyphose sévère peut comprimer les poumons et rendre la respiration difficile, compliquant ainsi les fonctions vitales.

L'impact psychologique des pathologies lombaires est tout aussi important. La douleur chronique peut entraîner des sentiments de frustration, d'anxiété et de dépression. Les personnes souffrant de ces affections peuvent se sentir isolées et éprouver des difficultés à maintenir des relations sociales, exacerbant leur détresse émotionnelle. La peur constante de la douleur peut également restreindre leurs activités et leurs loisirs, limitant leur participation à des événements sociaux et réduisant leur plaisir de vivre. En conséquence, la qualité de vie des personnes atteintes de pathologies lombaires est souvent considérablement diminuée, tant sur le plan physique que psychologique [11.19.20] .

I.4. Les Systèmes d'acquisition d'images

Les systèmes d'acquisition d'images jouent un rôle essentiel dans la capture et le traitement de données visuelles, qu'il s'agisse de simples photographies ou d'images médicales complexes.

En combinant l'optique, l'électronique et le traitement numérique d'images, ces systèmes permettent de convertir des scènes visuelles en données numériques exploitables.

Ce processus est vital dans de nombreux domaines, notamment la médecine, l'ingénierie, la surveillance, la robotique et bien d'autres.

Ils permettent aux professionnels de la santé d'identifier les anomalies, de planifier les traitements et de surveiller l'évolution des maladies. Voici un aperçu des principales techniques d'imagerie utilisées dans ce domaine :

I.4.1. Imagerie par Résonance Magnétique (IRM)

L'IRM (imagerie par résonance magnétique) est un examen médical qui utilise un champ magnétique puissant et des ondes radio pour générer des images détaillées des organes et des tissus mous du corps. L'IRM est réalisée dans une machine spéciale appelée IRM, qui se compose de deux éléments principaux :[21]

- **L'aimant** : Un grand aimant en forme de tube crée un champ magnétique puissant qui entoure le patient.

- **L'ordinateur et la console de commande** : Un ordinateur puissant contrôle l'aimant et les ondes radio, et traite les signaux générés par le corps du patient pour créer les images IRM.



Figure I.16. Un appareil d'imagerie par résonance magnétique (IRM) [22]

Cet appareil se présente comme un grand tunnel de près de 2 mètres de long au sein duquel une table vient se glisser. Pour cet examen, le patient est donc totalement « enfermé » dans l'appareil [21].

La salle informatique (PC room)

La salle informatique, également appelée salle de contrôle, abrite l'ordinateur et la console de commande de l'IRM. Cette salle est généralement située à proximité immédiate de la machine IRM elle-même. Elle doit être conçue pour protéger l'équipement électronique des interférences électromagnétiques (IEM) générées par l'aimant puissant.




Figure I.17. Ordinateur de contrôle de salle IRM [23]

Fonctions de la salle informatique

- **Contrôle de l'IRM** : L'opérateur de l'IRM utilise la console de commande dans la salle informatique pour contrôler tous les aspects de l'examen, y compris le positionnement du patient, l'acquisition des images et les paramètres de séquence.
- **Traitement des images** : L'ordinateur traite les signaux bruts générés par le corps du patient pour créer les images IRM en 2D et 3D.
- **Stockage des images** : Les images IRM sont stockées sur un disque dur ou un serveur dans la salle informatique pour une consultation ultérieure par le médecin et le patient.
- **Réseau** : La salle informatique peut être connectée au réseau informatique de l'hôpital pour permettre le transfert des images IRM vers d'autres systèmes informatiques [24].

La machine IRM et la salle informatique sont connectées par un système de câbles qui transmettent les signaux entre les deux composants. Ces câbles doivent être blindés pour éviter les interférences IEM.

Applications de l'IRM

L'IRM est utilisée dans de nombreuses applications médicales, notamment :

- **Diagnostic des tumeurs**: il est particulièrement efficace pour détecter les tumeurs du cerveau, de la moelle épinière, des muscles, des os et d'autres organes. Elle permet de visualiser la taille, la forme et l'étendue des tumeurs, ainsi que leur relation avec les structures environnantes.

- **Évaluation des lésions cérébrales:** il peut être utilisée pour diagnostiquer des accidents vasculaires cérébraux, des traumatismes crâniens, des infections cérébrales et d'autres maladies du cerveau. Elle permet de visualiser les lésions cérébrales et de suivre leur évolution au fil du temps.
- **Exploration des articulations et des ligaments:** L'IRM est utile pour diagnostiquer des lésions des articulations, des ligaments, des tendons et des ménisques. Elle permet de visualiser les structures internes des articulations en détail et de détecter des déchirures, des inflammations et d'autres anomalies.
- **Examen des organes internes:** L'IRM peut être utilisée pour examiner des organes tels que le foie, les reins, le cœur, les poumons et les glandes surrénales. Elle permet de détecter des tumeurs, des infections et d'autres pathologies[25].

Avantages

- **Imagerie détaillée**
- **Pas de radiation**
- **Bonne visualisation des tissus mous** (tels que le cerveau, les muscles, les ligaments et les organes internes.)
- **Capacité de contraste:** L'utilisation de produits de contraste à base de gadolinium permet d'améliorer la visualisation de certains tissus et structures.

I.4.2. Tomodensitométrie (Scanner)

Un scanner, scientifiquement appelé « tomodensitomètre » (TDM), est un appareil émettant de faibles doses de rayons X vers la partie du corps à analyser. Cette technique repose sur l'absorption des rayons par les tissus, permettant d'obtenir des images en coupes fines du corps.

Ces images sont ensuite traitées par ordinateur pour reconstituer des vues en deux ou trois dimensions. Contrairement aux radiographies classiques qui produisent une image bidimensionnelle superposant différentes structures, le scanner permet de visualiser les organes et les tissus en 3D, offrant ainsi une meilleure précision pour le diagnostic médical [26].



Figure I.18.Un appareil de scanner médical [27]

Fonctionnement

Le scanner projette un faisceau de rayons X fin et collimaté sur le corps du patient. Ce faisceau traverse différentes parties du corps, dont certaines absorbent plus de rayons X que d'autres en fonction de leur densité. Des détecteurs situés en face du patient mesurent l'intensité des rayons X traversant le corps.

Un ordinateur puissant utilise ensuite ces données pour reconstruire des images en coupes transversales du corps. L'épaisseur des coupes peut être ajustée en fonction de la zone à examiner. Les images obtenues sont généralement visualisées sur un écran d'ordinateur sous forme de coupes fines, mais peuvent également être reconstruites en 3D pour une meilleure visualisation des structures anatomiques[26].

Applications

Le scanner est utilisé dans de nombreuses applications médicales, notamment :

- **Détection des tumeurs, des infections et d'autres anomalies:** Le scanner permet de visualiser les tumeurs, les abcès, les fractures et d'autres anomalies avec une grande précision, ce qui facilite le diagnostic et le suivi du traitement.
- **Évaluation des traumatismes:** Le scanner est souvent utilisé après des accidents ou des blessures graves pour évaluer l'étendue des lésions aux organes internes, aux os et aux vaisseaux sanguins.

- **Planification de procédures médicales:** Le scanner peut être utilisé pour guider des interventions chirurgicales et d'autres procédures médicales, telles que les biopsies ou les injections de produits de contraste[26].

Avantages du scanner

- **Imagerie détaillée en 3D:** Le scanner offre une visualisation plus détaillée des structures anatomiques que les radiographies classiques, ce qui facilite le diagnostic et le suivi du traitement.
- **Rapidité:** L'examen est généralement réalisé en quelques minutes.
- **Non invasif:** Le scanner n'implique aucune incision ni injection, ce qui en fait une procédure relativement confortable pour le patient[26].

Inconvénients du scanner

- **Exposition aux rayonnements X:** Le scanner expose le patient à des rayonnements X, bien que la dose soit généralement faible.
- **Contraste iodé:** Dans certains cas, un produit de contraste iodé est injecté par voie intraveineuse pour améliorer la visualisation de certaines structures. Ce produit peut provoquer des réactions allergiques chez certaines personnes [26].

I.4.3. Radiographie

Une radiographie est un examen médical d'imagerie permettant de visualiser une partie ou la totalité d'une zone corporelle. Cet examen nécessite l'utilisation de rayons X pour leur capacité à traverser les tissus de façon plus ou moins importante en fonction de leur densité. Une source émettrice de rayons X est alors placée devant la partie du corps à étudier tandis qu'un détecteur est localisé à l'arrière. Les molécules lumineuses émises vont traverser le corps en étant plus ou moins absorbés par les tissus sur leur passage. C'est ainsi que l'on peut différencier les os des muscles sur les clichés de radiographie[27].



Figure I.19. Un appareil de radiographie [28]

Les images radiographiques sont généralement capturées sur un film ou un capteur numérique. Le film est ensuite développé pour créer une image physique, tandis que le capteur numérique envoie les données à un ordinateur pour traitement et visualisation. Le PC permet de :

- ✓ Ajuster la luminosité, le contraste et d'autres paramètres de l'image.
- ✓ Appliquer des filtres pour améliorer la visibilité de certaines structures.
- ✓ Stocker et archiver les images numériques.
- ✓ Transmettre les images à d'autres professionnels de santé.

Avantages

- Technique simple et accessible:
- Imagerie rapide
- Bonne résolution des structures osseuses
- Faible coût:
- Pas de préparation particulière

I.4.4. L'échographie

L'échographie, aussi appelée l'ultrasonographie, est une technique d'imagerie médicale qui utilise des ultrasons pour visualiser les organes et les structures internes du corps. Les ultrasons sont des ondes sonores à haute fréquence qui ne sont pas audibles par l'oreille humaine. Lorsqu'ils sont émis par une sonde et qu'ils traversent les tissus, les ultrasons sont réfléchis par

les organes et les structures internes. Ces échos réfléchis sont ensuite captés par la sonde et transformés en images en temps réel sur un écran Figure [29].



Figure I.20. Un appareil d'échographie [31]

Le médecin utilise un gel de contact qui contient de l'eau et permet la transmission des ultrasons (US) entre la sonde et la peau ; la sonde est « promenée » sur la peau et explore de façon dynamique la région demandée.

La sonde envoie des US qui sont réfléchis par les tissus : le signal perçu est traité par l'échographe qui retranscrit une image sur l'écran en nuances de gris.

Applications

L'échographie est utilisée dans de nombreuses applications médicales, notamment :

- Grossesse
- Abdomen
- Appareil circulatoire
- Thyroïde
- Articulations et muscles

En résumé, le choix de la technique d'imagerie médicale la plus appropriée dépend de plusieurs facteurs, tels que la pathologie suspectée, les besoins du patient et les contre-indications. Le médecin évaluera chaque cas individuellement et prescrira l'examen le plus pertinent pour obtenir un diagnostic précis et guider la prise en charge thérapeutique.

I.5. Conclusion

Ce premier chapitre a établi une base solide pour comprendre le contexte médical essentiel à l'étude des pathologies lombaires. En détaillant l'anatomie et le fonctionnement du rachis, nous

avons mis en évidence l'importance de cette structure centrale du corps humain dans le soutien physique, la protection de la moelle épinière, et la facilitation des mouvements.

Nous avons également exploré les principales pathologies lombaires, telles que la scoliose, l'hernie discale et la lordose, en soulignant leurs caractéristiques, leurs causes et leurs impacts sur la qualité de vie des patients.

Enfin, nous avons examiné les systèmes d'acquisition d'images médicales, notamment l'IRM, le scanner, la radiographie et l'échographie, en illustrant comment ces technologies permettent un diagnostic précis et une évaluation détaillée des pathologies lombaires.

Cette exploration approfondie du contexte médical est cruciale pour saisir les défis et les opportunités présentés par l'application du Deep Learning dans la classification non supervisée d'images pour le diagnostic des pathologies lombaires. Le cadre médical ainsi établi pave la voie à une compréhension plus approfondie et à des innovations potentielles dans ce domaine en pleine évolution.

Chapitre II
Apprentissage Automatique et Profond

II.1. Introduction

L'intelligence artificielle (IA) est une branche de l'informatique qui permet aux systèmes d'apprendre et d'exécuter des tâches normalement associées à l'intelligence humaine, telles que la reconnaissance vocale, la prise de décisions ou la perception visuelle.

Depuis les premières explorations de cette discipline par des visionnaires comme Alan Turing dans les années 1950, l'IA a considérablement évolué, intégrant des sous-disciplines clés comme l'apprentissage automatique (Machine Learning ou ML) et l'apprentissage profond (Deep Learning ou DL). L'IA exploite des algorithmes qui détectent des modèles à partir de vastes ensembles de données, lui permettant ainsi de prévoir et de s'adapter aux changements de manière autonome. Elle est capable de prendre des décisions de façon autonome, améliorant ainsi l'intelligence humaine en fournissant des informations précieuses et en augmentant la productivité

Ce chapitre explore les technologies d'apprentissage automatique et profond, en détaillant leurs principes fondamentaux, méthodes, applications et l'impact significatif de ces innovations dans divers domaines, notamment le médical.

II.2. Apprentissage Automatique

II.2.1. Définition du Machine Learning

L'apprentissage automatique, aussi connu sous le nom de **machine learning** (ML), est un domaine de l'intelligence artificielle (IA) et une technique de programmation informatique qui utilise des probabilités statistiques pour donner aux ordinateurs la capacité d'apprendre par eux-mêmes sans programmation explicite. Le machine learning utilise des programmes de développement qui s'ajustent chaque fois qu'ils sont exposés à différents types de données en entrée. Contrairement aux programmes traditionnels qui suivent des instructions prédéfinies, les algorithmes de machine learning apprennent à partir de données, ce qui leur permet d'identifier des patterns, de faire des prédictions et de prendre des décisions autonomes [31.32].

L'objectif de base du machine learning est "d'apprendre à apprendre" aux ordinateurs – et par la suite, à agir et réagir – comme le font les humains, en améliorant leur mode d'apprentissage et leurs connaissances de façon autonome sur la durée.

II.2.2. Principe du Machine Learning :

Le principe fondamental du machine learning repose sur l'utilisation d'algorithmes capables d'analyser de grandes quantités de données et d'en extraire des connaissances utiles.

Ces algorithmes s'inspirent de divers concepts mathématiques et statistiques, ainsi que du fonctionnement du cerveau humain.

Le processus d'apprentissage automatique se déroule généralement en plusieurs étapes :

1. **Collecte de données** : Rassembler un ensemble de données volumineux et de qualité pour entraîner l'algorithme.
2. **Prétraitement des données** : Nettoyer et préparer les données pour les rendre utilisables par l'algorithme.
3. **Sélection du modèle** : Choisir un algorithme de machine learning adapté à la tâche à accomplir.
4. **Entraînement du modèle** : Appliquer l'algorithme aux données d'entraînement afin qu'il apprenne à identifier les patterns et à faire des prédictions.
5. **Évaluation du modèle** : Tester le modèle sur des données non utilisées pour l'entraînement afin d'évaluer ses performances.
6. **Déploiement du modèle** : Intégrer le modèle dans une application ou un système pour qu'il puisse être utilisé pour faire des prédictions ou prendre des décisions [32].

II.2.3. Méthodes d'Apprentissage Automatique :

On peut classer les méthodes d'apprentissage automatique en plusieurs catégories :

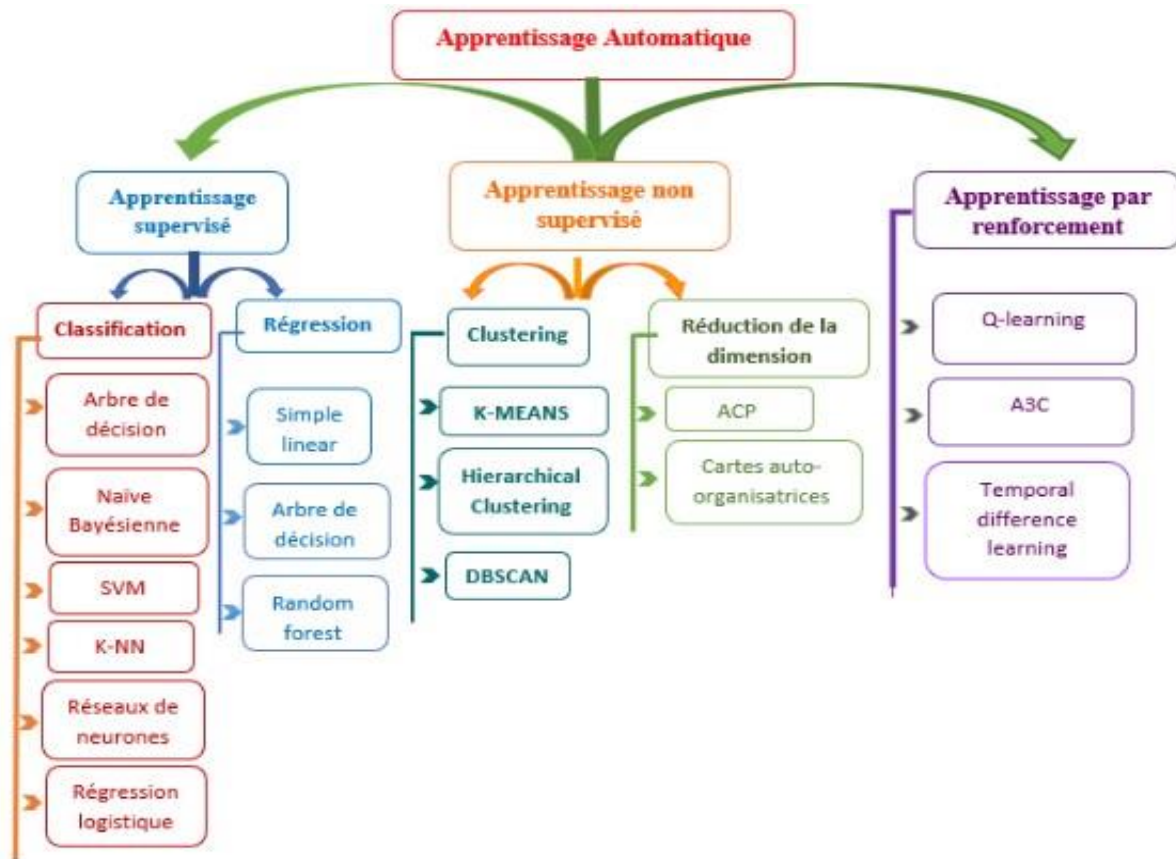


Figure II.1. Les catégories d'apprentissage automatique

La figure II.1 montre les trois principaux types d'apprentissage automatique: supervisé, non supervisé et par renforcement. Elle montre également quelques exemples de méthodes d'apprentissage automatique pour chaque catégorie.

II.2.3.1. Apprentissage Automatique Supervisé :

L'apprentissage supervisé est une technologie élémentaire mais stricte. Il utilise des **données étiquetées**, c'est-à-dire des données pour lesquelles la sortie souhaitée est déjà connue. [33.34]

(figure II.2)

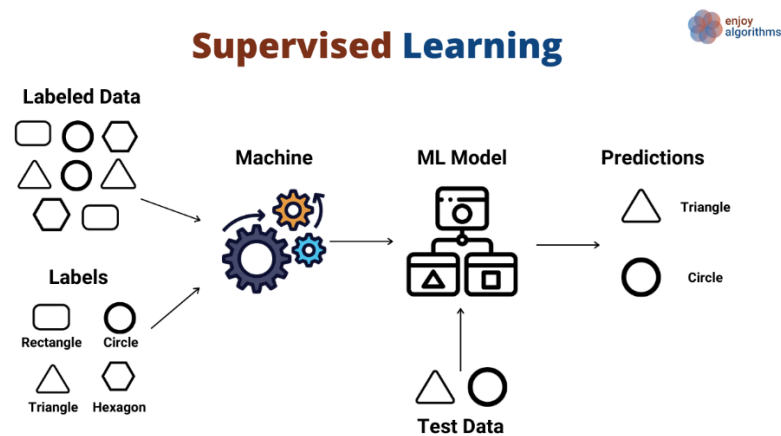


Figure II.3. Apprentissage supervisé [35]

L'objectif est d'entraîner le modèle choisi pour qu'il puisse prédire correctement la sortie pour des entrées non étiquetées.

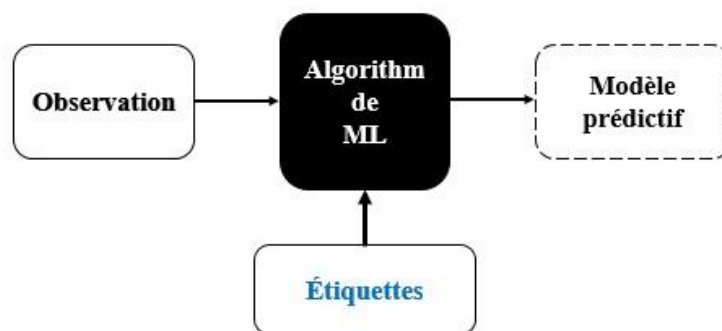


Figure II.4. Algorithme d'apprentissage automatique supervisée

Le schéma montre les étapes suivantes:

1. **Observation:** La première étape consiste à collecter des données d'observation. Ces données peuvent être sous forme de texte, d'images, de vidéos ou de tout autre type de données.
2. **Algorithme:** L'algorithme d'apprentissage automatique est ensuite appliqué aux données d'observation. L'algorithme apprend à partir des données et crée un modèle.
3. **Modèle prédictif:** Le modèle prédictif est le résultat de l'apprentissage automatique. Il peut être utilisé pour faire des prédictions sur de nouvelles données.
4. **Étiquettes:** Les étiquettes sont les informations correctes associées aux données d'observation. Elles sont utilisées pour évaluer la performance du modèle prédictif.

Les principaux algorithmes du machine learning supervisé sont les suivants [36] :

- Forêts Aléatoires: Ensemble d'arbres qui votent pour la meilleure classe.
- Arbres de Décision: Arbre inversé avec des règles pour classifier les données.
- KNN: Classe d'une nouvelle donnée basée sur ses K voisins les plus proches.
- Régression Linéaire: Ligne droite qui minimise l'erreur entre la ligne et les données.
- Naïve Bayes: Probabilité de classe basée sur des caractéristiques indépendantes.
- SVM: Hyperplan qui maximise la marge entre les groupes de données.
- Régression Logistique: Probabilité de classification binaire (0 ou 1).
- Boosting Gradient: Combinaison de modèles faibles pour améliorer la précision.

II.2.3.2. Apprentissage Automatique Non Supervisé

L'apprentissage automatique non supervisé utilise des données **non étiquetées**, c'est-à-dire des données pour lesquelles la sortie souhaitée n'est pas connue[37].

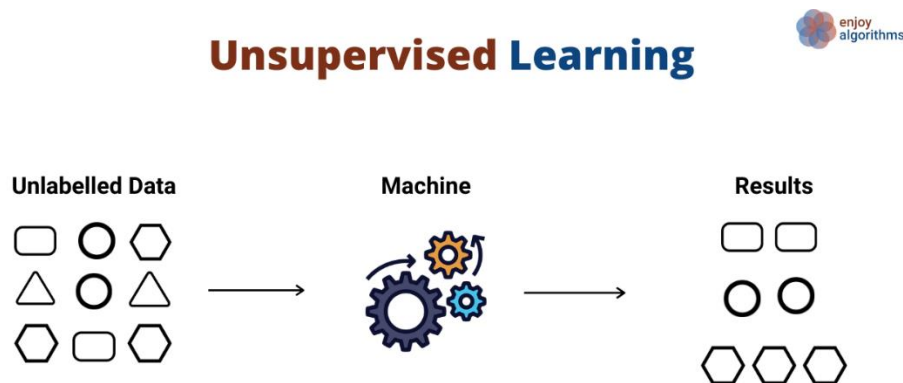


Figure II.5. Apprentissage non-supervisé [35]

l'objectif du système est d'identifier des caractéristiques communes aux données d'entraînement




Figure II.6. Algorithme d'apprentissage automatique non supervisée

L'algorithme apprend à identifier des patterns et des structures dans les données non étiquetées, ce qui peut être utile pour des tâches telles que le regroupement de données similaires ou la détection d'anomalies

Dans le cadre du machine learning non supervisé, l'algorithme détermine lui-même la structure de l'entrée (aucune étiquette n'est appliquée à l'algorithme). Cette approche peut être un but en soi (qui permet de découvrir des structures enfouies dans les données) ou un moyen d'atteindre un certain but. Cette approche est également appelée « apprentissage des caractéristiques » (feature learning).

Les principaux algorithmes du machine learning non supervisé sont les suivants :

K-Means, clustering/regroupement hiérarchique et réduction de la dimensionnalité.

- ✓ **K-Means:** Divise les données en groupes (k) en fonction de leur similarité.
- ✓ **Clustering Hiérarchique:** Regroupe les données de manière arborescente, du plus proche au plus éloigné.
- ✓ **Réduction de Dimensionnalité:** Transforme les données complexes en un format plus simple pour une analyse plus facile.[34, 37]

II.3. Apprentissage Profond

II.3.1. Définition du Deep Learning

L'apprentissage profond (DL) est un sous-domaine de l'apprentissage automatique (ML) qui s'inspire du fonctionnement du cerveau humain pour apprendre à partir de données. Il utilise des réseaux de neurones artificiels complexes, composés de plusieurs couches cachées, pour extraire des caractéristiques et des modèles à partir de données massives, souvent non structurées[34.38].




Figure II.7. Introduction à l'apprentissage profond [39]

II.3.2. Principe du Deep Learning

Le principe du deep learning repose sur l'utilisation de réseaux de neurones artificiels à plusieurs couches (d'où le terme "profond"). Chaque couche du réseau extrait des caractéristiques de plus en plus abstraites des données d'entrée.

Les couches initiales peuvent détecter des motifs simples (comme les bords dans une image), tandis que les couches plus profondes peuvent combiner ces motifs pour reconnaître des objets ou concepts plus complexes.

L'apprentissage se fait via un processus de rétropropagation de l'erreur, où les poids des connexions entre neurones sont ajustés pour minimiser l'erreur de prédiction du modèle[38].

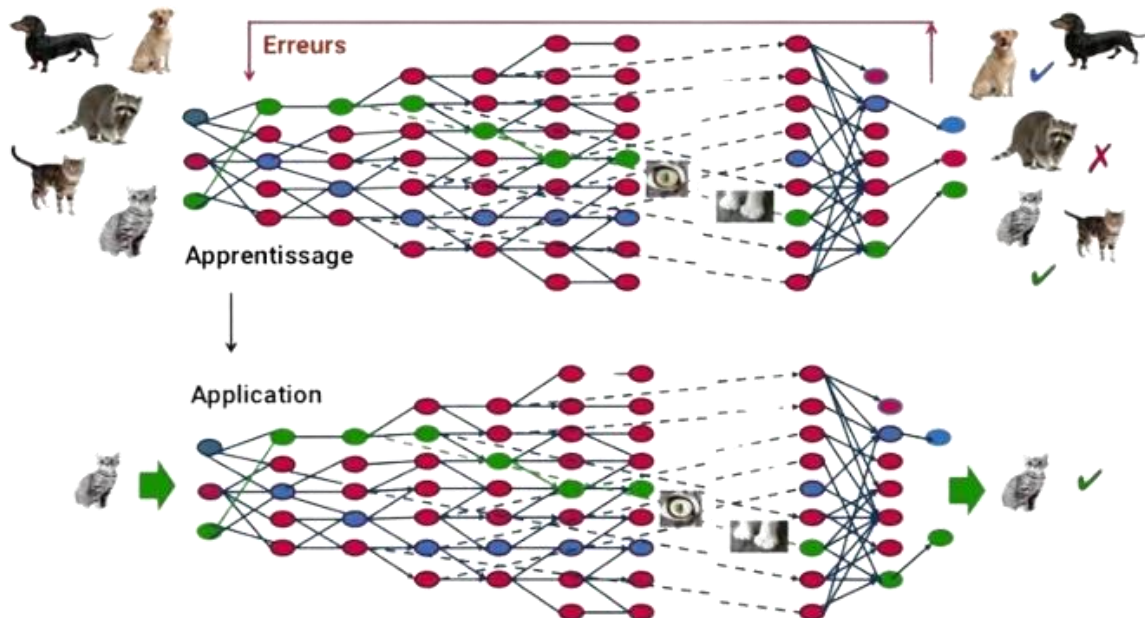


Figure II.8. Principe du Deep Learning [40]

II.3.3. Le processus d'apprentissage dans le Deep Learning

Le processus d'apprentissage dans le Deep Learning se déroule en plusieurs étapes:

1. Collecte et préparation des données:

La première étape consiste à collecter et à préparer les données qui seront utilisées pour entraîner le réseau de neurones. Les données peuvent être de différents types, telles que des images, du texte, des sons ou des données numériques.

2. Définition de l'architecture du réseau de neurones

L'architecture du réseau de neurones définit la structure du réseau, y compris le nombre de couches, le nombre de neurones par couche, le type de connexions entre les neurones et les fonctions d'activation utilisées. Le choix de l'architecture du réseau est crucial pour la performance du modèle.

3. Initialisation des paramètres du réseau

Les paramètres du réseau de neurones sont les poids des connexions entre les neurones. Ces poids sont initialisés à des valeurs aléatoires avant l'apprentissage.

4. Apprentissage du réseau de neurones

Le réseau de neurones apprend à partir des données en ajustant ses paramètres. Cet ajustement des paramètres se fait par le biais d'un algorithme d'optimisation, tel que la rétropropagation. L'algorithme d'optimisation calcule la différence entre la sortie prédite du réseau et la sortie réelle des données, et ajuste ensuite les paramètres du réseau de manière à minimiser cette différence [24].

5. Évaluation du réseau de neurones:

Une fois le réseau de neurones entraîné, il est évalué sur un ensemble de données de test distinct des données d'apprentissage. Cette évaluation permet de mesurer la performance du réseau sur des données qu'il n'a jamais vues auparavant.

6. Déploiement du réseau de neurones

Si le réseau de neurones obtient de bons résultats à l'évaluation, il peut être déployé dans une application réelle. Cela signifie que le réseau sera utilisé pour faire des prédictions sur de nouvelles données.

7. Surveillance et maintenance du réseau de neurones

Il est important de surveiller et de maintenir le réseau de neurones déployé afin de s'assurer qu'il continue à fonctionner de manière optimale. Cela peut impliquer de reentraîner le réseau sur de nouvelles données ou d'ajuster ses paramètres [41].

II.3.4. Applications du Deep Learning dans le Domaine Médical

Le domaine de la santé, englobant la médecine et les soins aux patients, est en constante évolution, toujours à la recherche de nouvelles technologies et méthodes pour améliorer la qualité des soins et l'efficacité des traitements.

La révolution numérique a introduit des outils puissants comme l'intelligence artificielle (IA) et le deep learning, qui ont transformé de nombreux aspects du secteur médical. Ces avancées permettent non seulement d'optimiser les processus médicaux, mais aussi de proposer des solutions innovantes pour des défis complexes.

Grâce au deep learning, le domaine médical a vu naître des applications variées et sophistiquées, allant de la détection précoce des maladies à l'assistance chirurgicale.

Explorons quelques-unes des applications les plus prometteuses du deep learning dans le domaine médical [42] :

- **Imagerie médicale:** Le DL peut être utilisé pour analyser des images médicales, telles que des radiographies, des tomographies par ordinateur et des IRM, pour détecter des anomalies et aider au diagnostic de maladies.
- **Robotique médicale:** Le DL peut être utilisé pour contrôler des robots chirurgicaux avec une précision accrue et une plus grande autonomie.
- **Développement de médicaments:** Le DL peut être utilisé pour accélérer le processus de développement de médicaments en prédisant la toxicité et l'efficacité des composés potentiels [43] .

II.4. Réseaux de Neurones

II.4.1. Qu'est-ce qu'un réseau neuronal

Un réseau neuronal est une méthode d'intelligence artificielle qui apprend à des ordinateurs à traiter les données d'une manière inspirée par le cerveau humain.

C'est un type de processus de machine learning appelé deep learning, qui exploite des nœuds, ou neurones, interconnectés dans une structure à plusieurs couches similaire au cerveau humain. Il crée un système adaptatif utilisé par les ordinateurs pour apprendre de leurs erreurs et s'améliorer en continu. Les réseaux neuronaux artificiels tentent de résoudre des problèmes complexes tels que résumer des documents ou reconnaître des visages, avec davantage de précision. [44]

Architecture d'un réseau neuronal simple

Un réseau neuronal de base comporte des neurones artificiels interconnectés en trois couches : [44].




Figure II.9. Architecture d'un réseau neuronal simple [45]

Couche d'entrée

Les informations du monde extérieur entrent dans le réseau neuronal artificiel par la couche d'entrée. Les nœuds d'entrée traitent les données, les analysent ou les catégorisent, et les transmettent à la couche suivante.

Couche cachée

Les couches cachées prennent leurs entrées de la couche d'entrée ou d'autres couches cachées. Les réseaux neuronaux artificiels peuvent avoir un grand nombre de couches cachées. Chaque couche cachée analyse la sortie de la couche précédente, la retravaille et la transmet à la couche suivante.

Couche de sortie

La couche de sortie donne le résultat final de tous les traitements de données effectués par le réseau neuronal artificiel. Il peut avoir des nœuds uniques ou multiples. Par exemple, si nous avons un problème de classification binaire (oui/non), la couche de sortie aura un nœud de sortie qui fournira le résultat sous forme de 1 ou 0. Cependant, si nous avons un problème de classification multi-classes, la couche de sortie peut être constituée de plus d'un nœud de sortie.

Poids (Weights)

Les poids sont des coefficients appliqués aux entrées d'un neurone pour ajuster leur importance relative. Ils sont essentiels pour l'apprentissage, car leurs ajustement permet au réseau de s'améliorer en minimisant l'erreur.

Chaque neurone est associé à un poids synaptique. Lorsqu'une donnée d'entrée entre dans un neurone, le poids sur le neurone est multiplié par sa valeur d'entrée.

Fonctions d'Activation

Les Fonctions d'Activation sont des formules mathématiques qui s'activent dans certaines conditions.

Lorsque les neurones calculent la somme pondérée des entrées et le poids, elles sont transmises à la fonction d'activation, qui vérifie si la valeur calculée dépasse le seuil spécifié. Si la valeur calculée est supérieure au seuil, la fonction d'activation est activée et une valeur de sortie est calculée. Cette valeur est ensuite transmise aux couches suivantes ou précédentes, selon la complexité du réseau, ce qui peut aider les réseaux de neurones à ajuster les poids de leurs neurones. Quelques exemples courants

Tableau II.1. Les fonctions d'activation les plus importants dans le deep learning [46]

Fonction d'activation	Description	Formule mathématique	Avantages	Applications courantes
Sigmoïde	Transforme les entrées en valeurs entre 0 et 1, souvent utilisée pour la classification binaire.	$f(x) = 1 / (1 + \exp(-x))$	Sorties normalisées entre 0 et 1, simple à implémenter	Classification binaire (par exemple, prédire si une image contient un chat ou un chien)

<p>ReLU (Rectified Linear Unit)</p>	<p>Renvoie l'entrée si elle est positive, 0 sinon.</p>	$F(x) = \max(0, x)$	<p>Simple à implémenter, rapide à calculer,</p>	<p>Couches cachées des réseaux de neurones convolutifs (par exemple, pour la reconnaissance d'images)</p>
<p>Softmax</p>	<p>Transforme un vecteur d'entrées en un vecteur de sorties probabilistes où la somme des sorties est égale à 1.</p>	$f(x_i) = \frac{\exp(x_i)}{\sum(\exp(x_j))}$	<p>Sorties probabilistes normalisées, utile pour la classification multi-classes</p>	<p>Couche de sortie des réseaux de neurones pour la classification multi-classes (par exemple, pour identifier le type d'objet dans une image)</p>

Architecture d'un réseau neuronal profond :

Les réseaux neuronaux profonds, ou réseaux de deep learning, possèdent plusieurs couches cachées avec des millions de neurones artificiels reliés entre eux.




Figure II.10. Architecture d'un réseau neuronal profond [47]

Théoriquement, les réseaux neuronaux profonds peuvent mettre en correspondance n'importe quel type d'entrée avec n'importe quel type de sortie.

Cependant, elles nécessitent également beaucoup plus d'entraînement par rapport aux autres méthodes de machine learning.

La profondeur d'un réseau de neurones artificiels (RNA) fait référence au nombre de couches cachées qu'il possède.

- Réseau peu profond: Un réseau avec peu de couches cachées, généralement une ou deux.
- Réseau profond: Un réseau avec plusieurs couches cachées, souvent des dizaines ou des centaines

Les réseaux profonds ont la capacité de capturer des **relations plus complexes** entre les données d'entrée et la sortie souhaitée, par rapport aux réseaux peu profonds.

Bien qu'un réseau de neurones à une seule couche puisse effectuer des prédictions approximatives, l'ajout de couches cachées supplémentaires permet d'optimiser et d'améliorer la précision des résultats. L'apprentissage en profondeur est à la base de nombreuses applications et services d'intelligence artificielle (IA) qui améliorent l'automatisation en exécutant des tâches analytiques et physiques sans intervention humaine. [44]

Les types de réseaux neuronaux

Le domaine des réseaux de neurones artificiels (RNA) est vaste et en constante évolution, avec de nouvelles architectures et des variantes apparaissant régulièrement[48].

Voici quelques-uns des **types de réseaux de neurones les plus courants**:

1. Réseaux de neurones perceptrons (monocouche)

- Les plus simples, composés de neurones perceptrons à une seule couche.
- Apprennent des fonctions linéaires séparables.
- Utilisés pour des tâches de classification binaire simples.

2. Réseaux de neurones multicouches

- Plus complexes, composés de plusieurs couches cachées de neurones artificiels.
- Peuvent apprendre des fonctions non linéaires complexes.
- Utilisés pour une large gamme de tâches, comme la reconnaissance d'images, le traitement du langage naturel et la prédiction de séries temporelles.

3. Réseaux de neurones convolutifs (CNN)

- Spécialisés dans le traitement d'images et de données spatiales.
- Utilisent des opérations de convolution pour extraire des caractéristiques locales des données d'entrée.
- Ont obtenu des résultats remarquables dans des tâches comme la reconnaissance d'objets, la segmentation d'images et la génération d'images.

4. Réseaux de neurones récurrents (RNN)

- Adaptés aux données séquentielles, comme le langage naturel ou les séries temporelles.
- Possèdent des connexions entre les neurones au sein d'une même couche, permettant de prendre en compte le contexte temporel.
- Utilisés pour des tâches comme la traduction automatique, la reconnaissance vocale et l'analyse de texte[48].

II 4.5 Architecture des CNN

Les réseaux de neurones convolutifs (CNN) sont un type d'architecture de réseau de neurones artificiels (RNA) .

Un réseau de neurones convolutif est un réseau de neurones composé par une succession de couches, dont au moins une seule, est une « couche de convolution ».

Ce type d'architecture est conçu pour extraire automatiquement des caractéristiques (features) à partir d'un ensemble de données non structurées, afin de reconnaître des objets.

Lors de l'apprentissage des réseaux CNN, la hauteur et la largeur du volume d'entrée diminuent grâce à l'application d'une fonction d'activation, sur les résultats des couches de convolution, ou aux résultats des couches de convolution et des couches de Pooling, jusqu'à atteindre « la couche fully-connected » [49] .

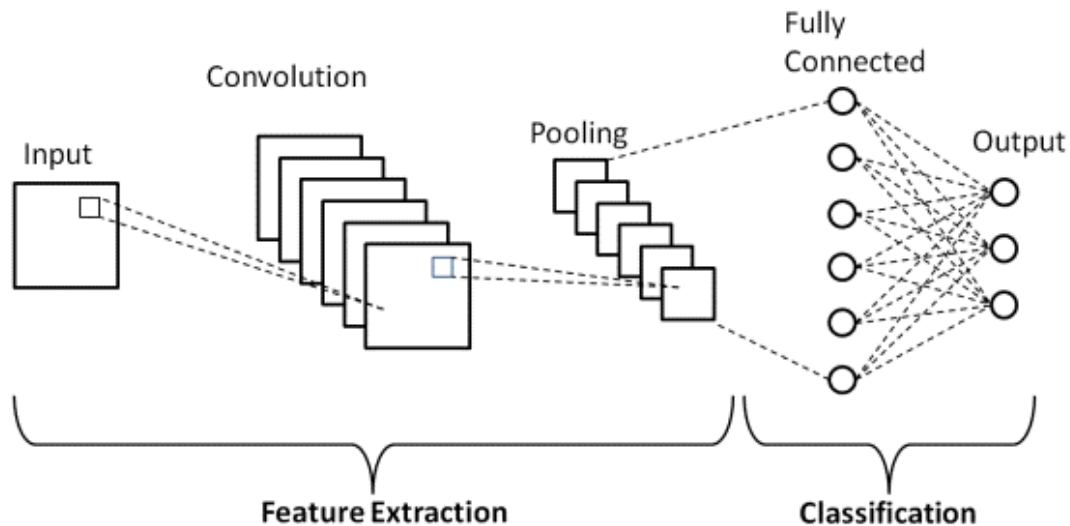


Figure II.11. Architecture des CNNs [50]

Un CNN typique est composé de plusieurs couches successives qui effectuent des opérations spécifiques [49] :

1. Couche d'entrée: Reçoit l'image d'entrée, généralement sous forme de matrice tridimensionnelle représentant les pixels de l'image (hauteur, largeur, canaux de couleur).

2. Couches convolutives:

- Appliquent des filtres convolutifs à l'image d'entrée.
- Un filtre convolutif est une petite matrice de poids qui glisse sur l'image, calculant une somme pondérée des pixels à chaque position.
- Ces opérations permettent d'extraire des caractéristiques locales, comme des bords, des textures ou des motifs, à partir de l'image.
- Plusieurs couches convolutives peuvent être empilées pour extraire des caractéristiques de plus haut niveau.

3. Couches de pooling:

- Réduisent la dimensionnalité des données en effectuant une opération de "pooling" sur les activations des couches convolutives précédentes.

4. Couches entièrement connectées:

- Appliquées à la sortie des couches convolutives et de pooling finales.

- Transforment la représentation spatiale en une représentation vectorielle.
- Permettent d'effectuer une classification ou une régression sur les caractéristiques extraites.

5. Couche de sortie:

- Produit la sortie finale du réseau, en fonction de la tâche à accomplir (classification, segmentation, génération, etc.).

II.4.6 Fonctionnalités des CNN dans la classification d'images :

Les réseaux de neurones convolutifs (CNN) sont particulièrement efficaces pour la classification d'images en raison de leur capacité à extraire automatiquement les caractéristiques pertinentes des images. Voici les principales fonctionnalités des CNN [51] :

- **Couches d'un réseau de neurones convolutif**

1. Couche de Convolution (Convolutional Layer)

- **Opération de Convolution :** La convolution est une opération mathématique qui combine deux ensembles d'informations. Dans le contexte des CNN, il s'agit de l'application de filtres sur une image pour produire des cartes de caractéristiques (feature maps).
- **Caractéristiques de cette couche :** Détecte des motifs locaux tels que des bords, des textures et des formes. Chaque filtre extrait une caractéristique spécifique de l'image, ce qui permet au réseau de détecter des motifs complexes.

2. Couche de Pooling (Pooling Layer)

- **Fonction :** Réduit la dimensionnalité des cartes de caractéristiques tout en conservant les informations importantes. Les deux types de pooling les plus courants sont le max pooling et l'average pooling.
- **Max Pooling :** Prend le maximum de chaque sous-région de la carte de caractéristiques.

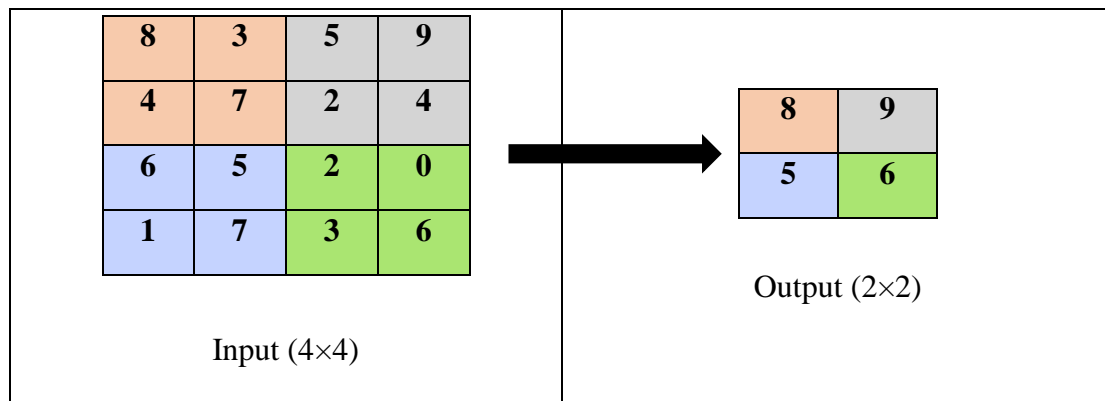


Figure II.12. Opération de max pooling [52]

- **Average Pooling** : Prend la moyenne de chaque sous-région de la carte de caractéristiques.
- **Min pooling** : Garde les valeurs les plus petites, ce qui peut être utile dans des cas spécifiques où les petites valeurs ont de l'importance




Figure II.13. Opération de min pooling [53]

- **Caractéristiques** : Diminue la taille des cartes de caractéristiques, réduisant ainsi le nombre de paramètres et le coût de calcul, tout en contrôlant le surajustement.

3. Couche d'Activation (Activation Layer)

- **Fonction** : Introduit de la non-linéarité dans le réseau pour permettre la modélisation de relations complexes. Les fonctions d'activation couramment utilisées sont ReLU, Sigmoid et Tanh.

4. Couches Fully Connected (Fc)

- **Fonction** : Chaque neurone de la couche est connecté à tous les neurones de la couche précédente. Transforme les cartes de caractéristiques extraites par les couches convolutives et de pooling en un vecteur de caractéristiques.

- **Caractéristiques** : Permet la classification en utilisant des couches de neurones denses et des fonctions d'activation pour prendre des décisions finales sur les classes des images.

5. Couche Flatten

- **Fonction** : Transforme les matrices de caractéristiques en un vecteur plat pour pouvoir les passer à une couche fully connected.
- **Caractéristiques** : Prépare les données pour les couches denses, en assurant que chaque pixel est pris en compte individuellement dans les décisions finales.

6. Couche Dropout

- **Fonction** : Pendant l'entraînement, désactive de manière aléatoire un certain pourcentage de neurones afin de prévenir le surajustement (overfitting).
- **Caractéristiques** : Améliore la généralisation du modèle en réduisant sa dépendance à des neurones spécifiques.

II.5. Conclusion :

Ce chapitre a offert une vue d'ensemble complète des technologies d'apprentissage automatique (ML) et d'apprentissage profond (DL), deux piliers essentiels de l'intelligence artificielle moderne. En introduisant les concepts de base et les principes qui sous-tendent ces technologies, il a été démontré comment le ML permet aux systèmes de reconnaître des motifs et de prendre des décisions basées sur des données, tandis que le DL, avec ses réseaux neuronaux complexes, approfondit cette capacité par des modèles encore plus sophistiqués et performants. En nous appuyant sur ces fondations solides, nous allons maintenant explorer les modèles de classification pour l'apprentissage par transfert

Chapitre III
Modèles de classification pour
l'apprentissage par transfert

III.1. Introduction

L'imagerie médicale joue un rôle essentiel dans le diagnostic et le traitement précis des troubles de la colonne vertébrale. La classification spinale, qui consiste à identifier et catégoriser ces troubles à partir d'images médicales, est une étape importante de ce processus clinique. Ce chapitre explore l'utilisation de l'apprentissage par transfert pour automatiser et améliorer la précision de ces classifications.

Avant de plonger dans l'apprentissage par transfert et ses applications à la classification spinale, il est important de souligner l'existence de méthodes de classification spinale traditionnelles qui ont jeté les bases pour les avancées technologiques actuelles. Ces méthodes traditionnelles, bien que essentielles, présentent certaines limitations. Elles peuvent être chronophages(lent), subjectives et sujettes à une erreur humaine. De plus, l'analyse manuelle de grandes quantités d'images médicales peut être fastidieuse (Sans intérêt) et sujette à la fatigue. C'est là que l'apprentissage par transfert entre en jeu. En s'appuyant sur des modèles d'apprentissage profond pré-entraînés et des ensembles de données d'images médicales, l'apprentissage par transfert offre une approche automatisée et objective pour la classification spinale, améliorant potentiellement la précision, l'efficacité et la reproductibilité de ce processus.

Ce chapitre explore divers modèles de classification utilisés dans ce contexte, en mettant l'accent sur leurs architectures spécifiques telles que VGG16, VGG19, ResNet18, ResNet34 et DenseNet121. Nous examinerons également les différentes mesures d'évaluation employées pour évaluer leur efficacité dans cette application particulière. De plus, nous discutons des différentes mesures d'évaluation employées pour mesurer l'efficacité de ces modèles dans la classification des troubles de la colonne vertébrale.

III.2. Un bref parcours des travaux de classification Spinale

Dans le domaine médical, la classification des troubles de la colonne vertébrale, également appelée classification spinale, joue un rôle fondamentale dans le diagnostic et le traitement efficaces des différentes anomalies et pathologies affectant la colonne vertébrale. Les cliniciens, notamment les chirurgiens de la colonne vertébrale, s'appuient sur une approche multidisciplinaire pour évaluer ces troubles. Tout d'abord, une évaluation clinique du sujet est effectuée, corrélant les résultats cliniques avec les résultats des examens d'imagerie et les rapports des radiologues. En fonction de la gravité de la pathologie, un examen physique

approfondi peut être réalisé, suivi d'une évaluation détaillée de l'alignement et de l'équilibre de la colonne vertébrale à partir d'examens radiographiques et IRM. Ces évaluations comprennent des mesures telles que **l'angle lordotique**, **l'angle lombo-sacré**, **l'angle d'incidence pelvienne**, **la hauteur de la colonne lombaire**, ainsi que **la taille des disques intervertébraux postérieurs et antérieurs**.

Dans le cadre de la classification spinale, deux aspects clés sont abordés : l'évaluation du spondylolisthésis et l'évaluation de la lordose lombaire. Le spondylolisthésis, caractérisé par le désalignement d'une vertèbre par rapport à une autre en raison d'une fracture osseuse de stress appelée spondylolyse, est évalué en suivant **la classification de Meyerding**. En ce qui concerne l'évaluation de la lordose lombaire, plusieurs méthodes sont utilisées, notamment la **méthode de Cobb modifiée**, **l'indice d'Ishihara**, **la méthode Voutsinas et MacEwen**, **l'évaluation radiologique tangentielle de la lordose lombaire (TRALL)**, **la méthode de la tangente postérieure Harrison (HPTM)**, **la méthode du centroïde** et **la méthode de l'aire sous la courbe (AUC)**[54].

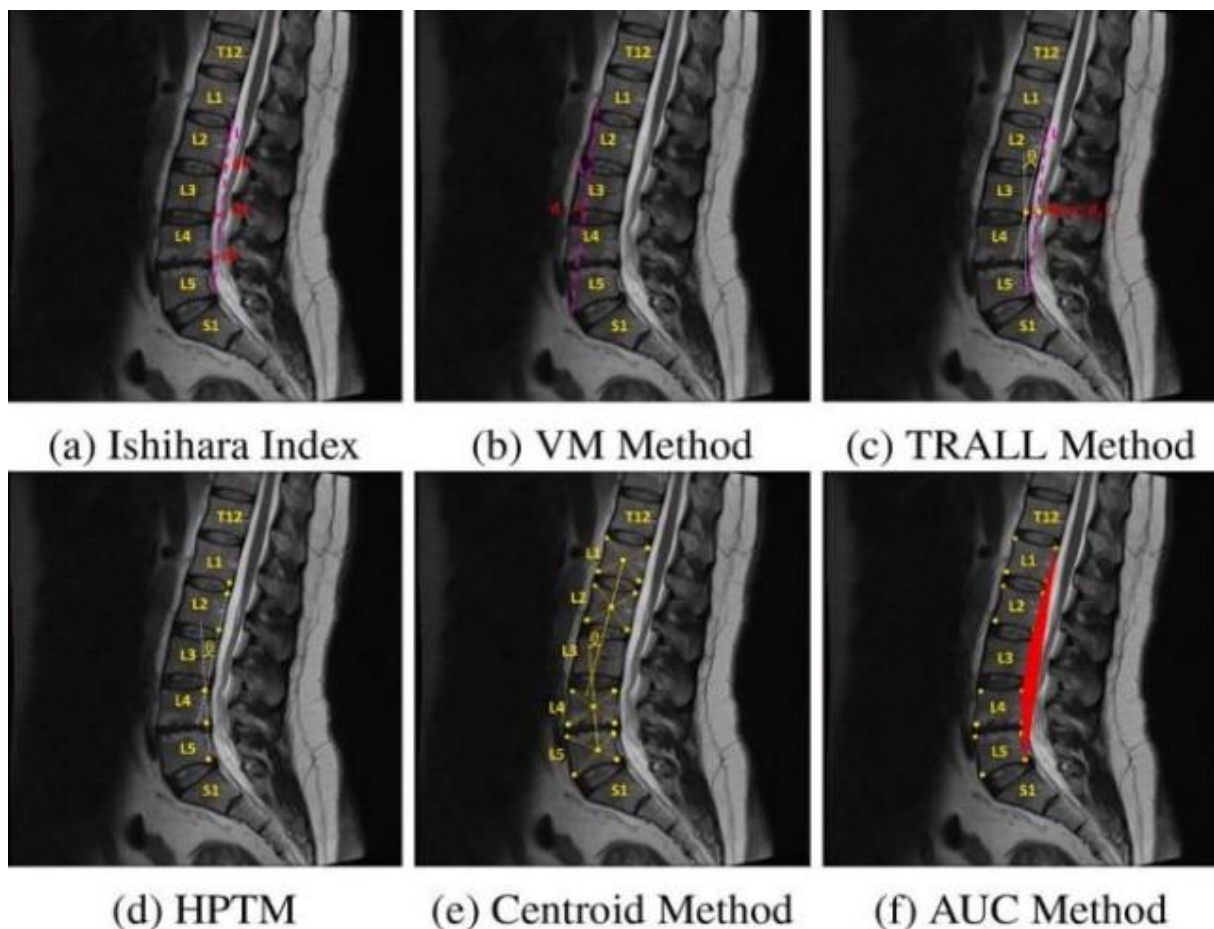


Figure III.1. Méthodes utilisées pour l'évaluation de la courbe lordotique lombaire [54]

Un résumé de certaines des techniques [54]

Classification de Meyerding

- Principe : Cette classification évalue le degré de glissement d'une vertèbre par rapport à une autre, généralement dans le contexte du spondylolisthésis, où une vertèbre se déplace vers l'avant par rapport à celle qui se trouve en dessous.
- Procédure : Le glissement est mesuré en pourcentage de la largeur du plateau vertébral supérieur de la vertèbre sous-jacente.
- Avantages : Simple à utiliser et permet de quantifier la gravité du spondylolisthésis de manière standardisée.
- Limites : Ne prend pas en compte les autres dimensions de l'instabilité vertébrale ou les symptômes cliniques.

Méthode de l'Indice d'Ishihara

- Principe : L'indice d'Ishihara mesure la courbure de la colonne vertébrale en utilisant un angle lordotique spécifique.
- Procédure : Un angle est calculé en traçant une ligne à partir du bord antérieur de la première vertèbre lombaire jusqu'au bord antérieur de la cinquième vertèbre lombaire.
- Avantages : Simple et rapide à utiliser.
- Limites : Peut ne pas capturer les subtilités des courbes anormales.

Méthode de Voutsinas et MacEwen (VM)

- Principe : La méthode VM utilise des points spécifiques le long de la colonne pour calculer plusieurs angles.
- Procédure : Des lignes sont tracées entre divers points vertébraux pour évaluer les angles individuels formés par les vertèbres.
- Avantages : Offre une analyse plus détaillée et précise de la courbure.
- Limites : Plus complexe et nécessite plus de temps pour effectuer les mesures.

Méthode de l'Évaluation Radiologique Tangentielle de la Lordose Lombaire (TRALL)

- Principe : La méthode TRALL évalue la lordose lombaire en utilisant des tangentes à des points spécifiques sur les vertèbres.
- Procédure : Des tangentes sont tracées sur les bords antérieurs et postérieurs des vertèbres pour former une courbe qui est ensuite analysée.
- Avantages : Permet une évaluation détaillée et précise de la courbe lordotique.
- Limites : Peut être complexe à mettre en œuvre et nécessiter une formation spécifique.

Méthode du Centroïde

- Principe : Utilise des centroïdes des vertèbres pour calculer l'angle d'intersection.
- Procédure : Les centroïdes (points centraux) sont identifiés au lieu des points d'angle. L'angle d'intersection θ entre les lignes passant par ces centroïdes est calculé.
- Avantages : Précise pour capturer la géométrie centrale de la courbure.
- Limites : Plus complexe et nécessite une analyse détaillée pour identifier les centroïdes

Méthode de l'Aire Sous la Courbe (AUC)

- Principe : Utilise une courbe tracée reliant les coins postérieurs des vertèbres lombaires.
- Procédure : Une courbe est tracée entre les coins postérieurs des vertèbres lombaires. Le point du coin supérieur est connecté directement au point du coin inférieur. L'aire sous cette courbe est mesurée pour évaluer la lordose lombaire.
- Avantages : Permet une évaluation continue et détaillée de la courbure.
- Limites : Complexe à mettre en œuvre et nécessite des logiciels spécialisés pour calculer l'aire sous la courbe.

Les méthodes traditionnelles de classification spinale sont essentielles pour évaluer la lordose lombaire et le spondylolisthésis. Elles offrent des approches structurées pour quantifier les anomalies vertébrales, mais présentent des limites en termes de complexité. Malgré ces défis, elles restent fondamentales et servent de base pour les avancées technologiques futures, comme l'intégration du deep learning pour améliorer précision et efficacité des diagnostics.

III.3. Modèles d'entraînement explorés

Pour la classification d'images plusieurs modèles préentraînés ont été explorés pour leur capacité à classer ces images de manière efficace :

III.3.1. VGG16 (Visual Geometry Group 16-layer)

Le modèle VGG16 est une architecture de réseau neuronal convolutionnel profonde comprenant 16 couches, préentraînées sur le dataset ImageNet. Il est connu pour sa simplicité et son efficacité dans la reconnaissance d'images, grâce à ses couches de convolution et de pooling qui extraient et réduisent progressivement les caractéristiques des images, avec quelques modifications en ajoutant des couches personnalisées pour adapter les sorties à notre base de données utilisée.




Figure III.2. Modèle de vgg16 [55]

III.3.2. VGG19 (Visual Geometry Group 19-layer)

Similaire au VGG16, le VGG19 possède 19 couches et est également préentraîné sur ImageNet. L'ajout de trois couches de convolution supplémentaires permet au modèle de capturer des caractéristiques plus complexes et fines des images, améliorant ainsi la précision potentielle pour certaines tâches de classification d'images.




Figure III.3. Modèle de vgg19 [56]

III.3.3. ResNet18 (Residual Network 18-layer)

ResNet18 est un modèle de réseau de neurones résiduel comprenant 18 couches. Sa caractéristique principale est l'utilisation de "residual blocks" qui facilitent l'apprentissage de réseaux plus profonds en permettant un flux direct de gradients à travers les couches, ce qui atténue le problème de la dégradation lors de l'entraînement de réseaux très profonds.




Figure III.4. Architecture du resnet 18 [57]

III.3.4. ResNet34 (Residual Network 34-layer)

ResNet34 est une extension de ResNet18 avec 34 couches, offrant une capacité de modélisation plus importante tout en utilisant le même principe de "residual blocks". Ce modèle est particulièrement efficace pour apprendre des représentations complexes des données tout en maintenant une bonne performance de généralisation.

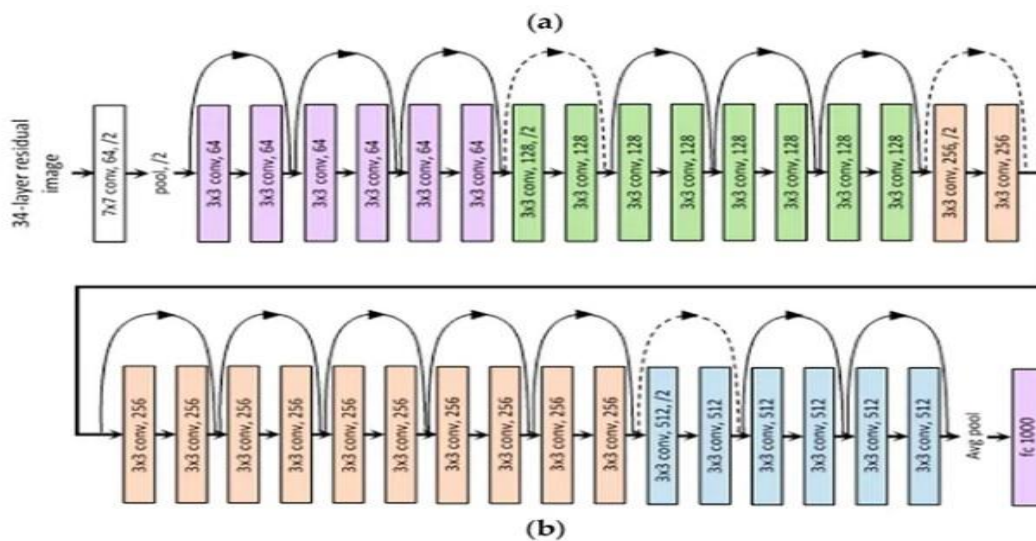


Figure III.5. Architecture du resnet 34 [58]

III.3.5. DenseNet121 (Densely Connected Convolutional Network 121-layer)

Le modèle DenseNet-121 est une architecture de réseau de neurones convolutifs profonds qui a été développée pour la classification d'images. Il se distingue par son architecture dense, où chaque couche reçoit des connexions directes de toutes les couches précédentes. Cela favorise un meilleur flux d'informations à travers le réseau et une utilisation plus efficace des caractéristiques extraites à différentes profondeurs.

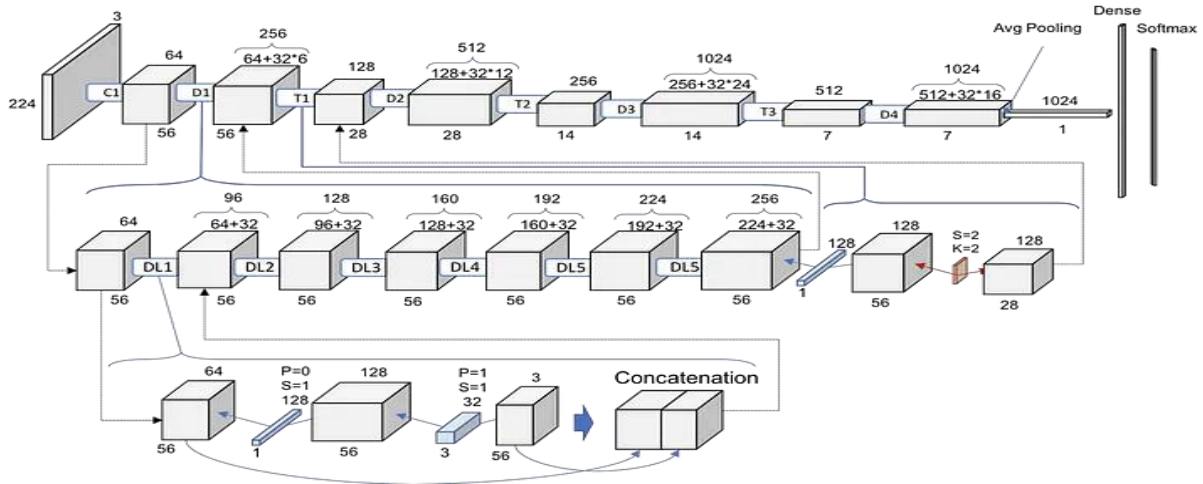


Figure III.6. Architecture du densnet 121 [59]

III.4. Métriques d'évaluation

Les métriques d'évaluation sont des outils essentiels pour juger les performances d'un modèle de classification. Elles permettent de quantifier l'exactitude et la qualité des prédictions effectuées par le modèle.[60]

III.4.1. Matrice de confusion

Une matrice de confusion est un tableau permettant de visualiser les performances d'un algorithme de classification. Elle met en relation les prédictions du modèle avec les valeurs réelles, permettant ainsi de calculer diverses métriques d'évaluation.

Tableau III.1. Tableau qui explique une matrice de confusion [60]

	Prédiction Positive	Prédiction Négative
Réel Positif	Vrai Positif (TP)	Faux Négatif (FN)
Réel Négatif	Faux Positif (FP)	Vrai Négatif (TN)

Tableau 4.1: Tableau qui explique une matrice de confusion

- **Vrai Positif (TP)** : Nombre de prédictions positives correctes.
- **Faux Négatif (FN)** : Nombre de prédictions négatives incorrectes (des positifs réels prédites comme négatifs).
- **Faux Positif (FP)** : Nombre de prédictions positives incorrectes (des négatifs réels prédites comme positifs).
- **Vrai Négatif (TN)** : Nombre de prédictions négatives correctes.

III.4.2. Critères d'évaluation

II.4.2.1 L'exactitude (accuracy)

L'exactitude est le rapport du nombre de prédictions correctes (vrais positifs et vrais négatifs) au nombre total de prédictions. Elle est donnée par la formule :

$$\text{Exactitude} = \frac{TP+TN}{TP+TN+FP+FN}$$

II.4.2.2 Précision

La précision est le rapport du nombre de vrais positifs au nombre total de prédictions positives. Elle est donnée par la formule :

$$\text{Précision} = \frac{TP}{TP+FP}$$

La précision est particulièrement importante lorsque le coût des faux positifs est élevé, par exemple dans les tests médicaux où un faux positif pourrait entraîner des traitements inutiles.

II.4.2.3 Rappel (recall) :

Le rappel, également appelé sensibilité ou taux de vrais positifs, est le rapport du nombre de vrais positifs au nombre total de positifs réels. Il est donné par la formule :

$$\text{Rappel} = \frac{TP}{TP+FN}$$

II.4.2.4. F1 score

Le F1 score est la moyenne harmonique de la précision et du rappel. Il fournit une mesure unique qui équilibre les deux métriques. Il est donné par la formule :

$$F\text{-score} = 2 \times \frac{\text{Précision} \times \text{Rappel}}{\text{Précision} + \text{Rappel}}$$

Le F1 score est particulièrement utile lorsque vous devez trouver un équilibre entre précision et rappel, surtout dans des situations où un compromis entre les deux est nécessaire.

III.5. Conclusion

Ce chapitre a présenté l'utilisation prometteuse de l'apprentissage par transfert pour la classification des troubles de la colonne vertébrale à partir d'images médicales. L'exploration de divers modèles de classification populaires, tels que VGG16, VGG19, ResNet18, ResNet34 et DenseNet121, a mis en lumière le potentiel de cette approche pour automatiser et améliorer la précision de ce processus clinique.

L'apprentissage par transfert, en combinaison avec l'apprentissage profond, ouvre des perspectives prometteuses pour révolutionner la classification spinale et améliorer les soins aux patients souffrant de troubles de la colonne vertébrale. En poursuivant des recherches dans ce domaine, nous pouvons espérer des avancées significatives dans le diagnostic et le traitement de ces pathologies dans les années à venir.

Chapitre IV
Développement et Évaluation
Comparative du Système de Classification
‘DetecLordose’

IV.1. Introduction

Ce chapitre présente le processus complet de développement, de mise en place et d'évaluation du système de classification 'DetecLordose'. Nous détaillons l'environnement matériel et logiciel utilisé, la méthodologie de traitement des données, la conception du modèle de réseau de neurones convolutifs (CNN) personnalisé, ainsi que les résultats obtenus. Un des objectifs principaux est de comparer les performances de notre modèle 'DetecLordose' avec d'autres modèles bien établis tels que VGG16, VGG19, DenseNet121, afin de choisir le plus adapté pour la prédiction du type de Lordose.

IV.2. Environnement de travail

IV.2.1. Hardware

Ce travail a été réalisé avec un ordinateur personnel :

Ordinateur

- Lenovo -N08OKSA
- Intel(R) Core (TM) i5-7200U CPU @ 2.50GHz 2.71 GHz
- RAM 12,00 Go
- GPU intégré
- 100 Gb d'espace

IV.2.2. Software

IV.2.2.1. Google Colab

Google Colab, ou Google Colaboratory, est un service basé sur le cloud offert par Google qui permet aux utilisateurs d'écrire et d'exécuter du code Python directement dans leur navigateur. C'est un outil particulièrement populaire pour les projets de machine learning, d'analyse de données et d'apprentissage profond, grâce à ses nombreuses fonctionnalités.

IV.2.2.2. Anaconda

Anaconda est une distribution de Python qui inclut un large éventail de bibliothèques et outils destinés à la data science et au machine learning. Avec Anaconda, on a pu créer des environnements virtuels spécifiques à notre projet, assurant ainsi la compatibilité des bibliothèques et des versions de Python nécessaires.

IV.2.2.3. Spyder

Spyder, inclus dans la distribution Anaconda, est un environnement de développement intégré (IDE) conçu pour le développement scientifique. Il fournit un éditeur de code avancé, un explorateur de variables pour visualiser les données en mémoire, et une intégration avec IPython pour une exécution interactive du code.

IV.2.2.4. Jupyter

Jupyter Notebook est un outil inclus dans Anaconda qu'on a utilisé pour l'exploration des données et le prototypage de modèles. Jupyter permet de créer des documents interactifs où le code, les visualisations et les textes explicatifs peuvent coexister. Cela a facilité la documentation des différentes étapes de projet de classification des images IRM de lordose.

IV.2.3. Bibliothèques utilisées

○ TensorFlow

Une bibliothèque open-source développée par Google pour le calcul numérique et l'apprentissage automatique. Elle est largement utilisée pour construire, entraîner et déployer des modèles de deep learning.

○ Keras

Une API haut niveau pour l'apprentissage profond, intégrée à TensorFlow. Keras permet de construire et d'entraîner des réseaux de neurones de manière simple et intuitive.

○ NumPy

Une bibliothèque fondamentale pour le calcul scientifique en Python. Elle offre un support pour des tableaux et des matrices multidimensionnels, ainsi que des fonctions mathématiques performantes.

○ cv2 (OpenCV)

Une bibliothèque open-source dédiée à la vision par ordinateur. Elle fournit des outils pour traiter des images et des vidéos, effectuer des opérations comme la détection d'objets, la reconnaissance faciale, et bien plus encore.

- **Scikit-learn**

Une bibliothèque open-source en Python dédiée à l'apprentissage automatique. Scikit-learn fournit des outils simples et efficaces pour l'analyse de données et le data mining, notamment pour les tâches de classification, régression, clustering, réduction de dimensionnalité, pré-traitement de données, et validation de modèles. Elle est construite sur NumPy, SciPy et Matplotlib, facilitant ainsi son intégration avec d'autres bibliothèques scientifiques en Python.

- **ImageDataGenerator**

Une classe de Keras utilisée pour la génération en temps réel de lots de données d'images avec augmentation. Elle permet de créer de nouvelles images à partir de celles existantes en appliquant des transformations comme des rotations, des décalages et des mises à l'échelle.

- **Matplotlib**

Une bibliothèque de visualisation de données en 2D. Elle permet de créer des graphiques, des diagrammes et des figures diverses de manière simple et flexible.

IV.3. Architecture Générale du système de classification 'DetecLordose'

La figure 1 présente un schéma générale du système de classification

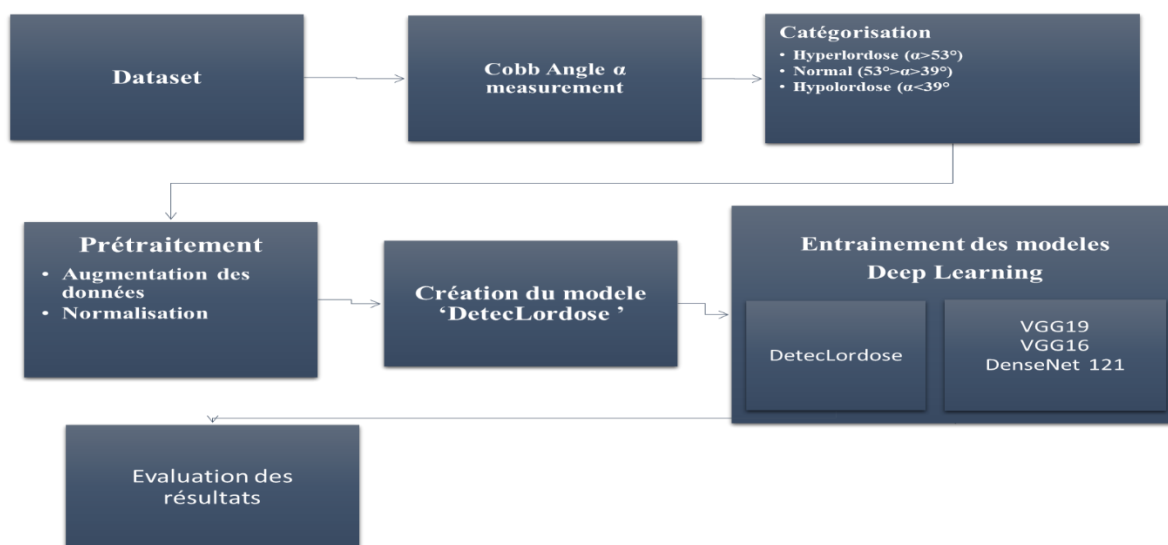


Figure IV.1. Schéma générale du système de classification

IV.3.1. Description du Dataset

IV.3.1.1. Description du dataset utilisé pour l'entraînement et la validation des modèles

Le Dataset "**Spinal MRI Images**" contient un total de 514 images de la colonne vertébrale obtenues par résonance magnétique (IRM), chaque image est de format 320x320 pixels au format png d'origine[61].

.Les images ont été redimensionnées 224x224 pour s'adapter aux modèles de Deep Learning explorés .Ces images se concentrent spécifiquement sur la région lombaire de la colonne vertébrale, incluant les vertèbres de L1 à L5. Elles sont destinées à des recherches dans le domaine de l'imagerie médicale, notamment pour le diagnostic et l'analyse des pathologies de la colonne vertébrale. Chaque image est annotée avec des informations pertinentes, incluant potentiellement des détails sur l'état de la colonne vertébrale (par exemple, la présence de hernies discales ou autres anomalies).

Les images sont organisées de manière à faciliter l'accès et l'analyse par les chercheurs et les professionnels de santé. Le dataset offre une base de données riche pour le développement et la validation de méthodes de traitement d'images, de segmentation, et de classification assistées par intelligence artificielle.

IV.3.1.2 Sources et caractéristiques des données collectées

Les données du dataset "**Spinal MRI Images**" proviennent d'examens de résonance magnétique réalisés sur des patients souffrant de diverses affections de la colonne vertébrale, y compris des conditions affectant la lordose lombaire. Ces images ont été collectées dans plusieurs institutions médicales pour garantir une diversité de cas cliniques et de pathologies. Les caractéristiques des images incluent diverses coupes de la colonne vertébrale, permettant d'identifier des anomalies telles que les hernies discales, les dégénérescences discales, et les variations de la courbure lordotique.

IV.3.2.L'angle de Cobb et Méthodologie de calcul

IV.3.2.1. Définition du Cobb angle

Le Cobb angle, souvent associé à l'évaluation de la scoliose, trouve également une application significative dans l'analyse de la lordose, une courbure normale antérieure de la colonne

vertébrale dans les régions cervicale et lombaire. Dans le contexte de la lordose lombaire, le Cobb angle mesure l'inclinaison angulaire entre les vertèbres les plus antérieures et postérieures de la courbure lombaire, généralement les vertèbres L1 et S1. Ce paramètre est important pour évaluer la normalité de la lordose lombaire et peut fournir des informations précieuses sur la santé de la colonne vertébrale

Une augmentation ou une diminution significative du Cobb angle dans la lordose lombaire peut être associée à des symptômes cliniques et des limitations fonctionnelles. Par conséquent, l'évaluation précise du Cobb angle dans la lordose lombaire revêt une importance capitale pour guider les interventions thérapeutiques, telle que la manipulation vertébrale, ou dans certains cas, la chirurgie, visant à restaurer la courbure normale de la colonne vertébrale et à atténuer les symptômes associés à la dysfonction lombaire.

IV.3.2.2. Calcul de L'angle de Cobb

La méthode de traitement des images utilisée repose sur un script python qui suit les étapes suivantes :

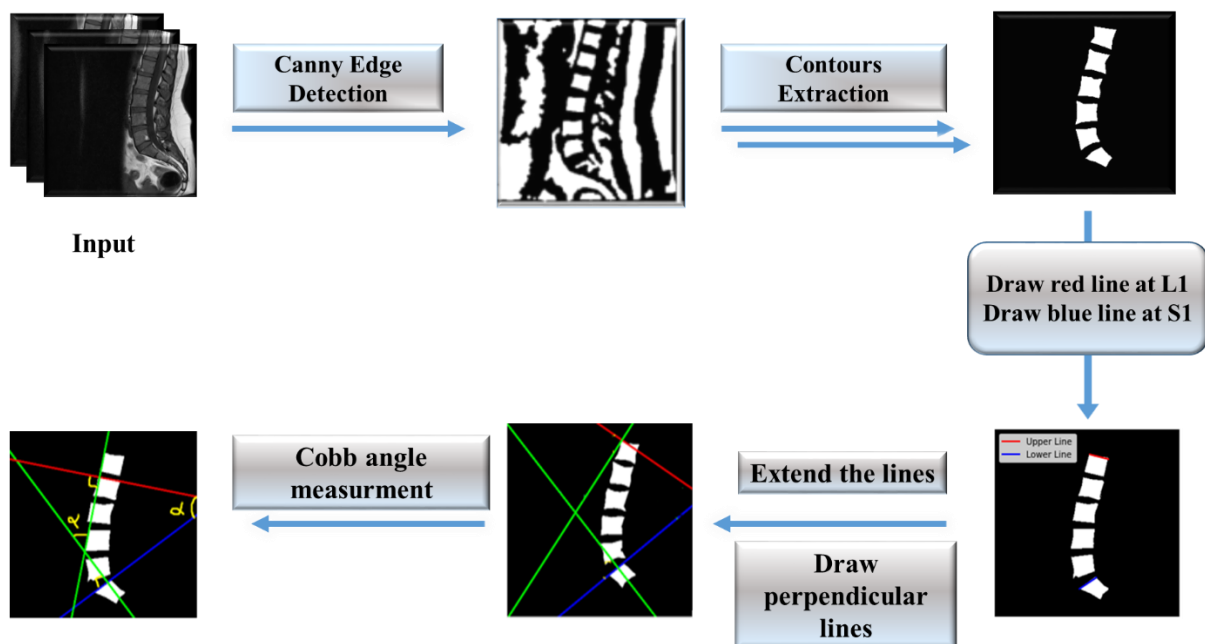


Figure IV.2. Processus de calcul de Cobb angle

- **Chargement de l'image et prétraitement :** L'image de la colonne vertébrale est d'abord chargée à partir du chemin spécifié. Ensuite, pour faciliter le traitement ultérieur, l'image est convertie en niveaux de gris. Un flou gaussien est appliqué pour réduire le bruit dans l'image, ce qui améliore la qualité des contours extraits.

Les contours de la colonne vertébrale sont identifiés à l'aide du détecteur de contours de Canny. Les contours sont ensuite trouvés dans l'image en utilisant la fonction `cv2.findContours()`. En utilisant les points des contours détectés, des lignes sont dessinées sur les cinq premiers points du premier et du sixième contours trouvés, représentant ainsi deux estimations de la direction de la colonne vertébrale

- **Calcul et formule**

L'angle de Cobb, noté par le symbole α (alpha), est calculé en traçant une ligne parallèle au plateau supérieur de la vertèbre supérieure et une autre ligne parallèle au plateau inférieur de la vertèbre inférieure. Des perpendiculaires sont tracées à partir de ces lignes, et l'angle de Cobb est défini comme l'angle formé par l'intersection de ces deux perpendiculaires. La formule pour calculer l'angle de Cobb (α) est donc :

$$M_{L1,S} = \frac{Y_{2y} - Y_{1y}}{X_{2x} - X_{1x}}$$

M : représente la pente des lignes,

Y_{1y} et Y_{2y} : représentent le rang sur l'axe des ordonnées (y),

X_{1x} et X_{2x} : représentent une virgule sur l'axe des abscisses (x).

IV.3.3. Catégorisation des données

Après avoir calculé les angles Cobb pour chaque image, une classification en trois catégories a été effectuée en fonction des valeurs angulaires obtenues. Les images ont été réparties en trois classes distinctes, chacune correspondant à un état spécifique de la courbure vertébrale :

- **"High Angles"** : Cette catégorie fait référence à une hyperlordose, caractérisée par des Cobb angles supérieurs à 53 degrés. *Une hyperlordose* indique une courbure excessive de la colonne vertébrale dans la région lombaire, ce qui peut entraîner des symptômes tels que des douleurs lombaires chroniques et une altération de la fonction motrice.
- **"Medium Angles"** : Cette catégorie représente des angles Cobb compris entre 53 et 39 degrés, correspondant à *un état* considéré comme *normal* de la courbure vertébrale.
- **"Low Angles"** : Cette catégorie désigne *une hypolordose*, caractérisée par des Cobb angles inférieurs à 39 degrés. Une hypolordose indique une courbure réduite de la colonne vertébrale dans la région lombaire, ce qui peut également entraîner des symptômes tels que des douleurs lombaires et une diminution de la flexibilité.

IV.3.4. Prétraitement des données

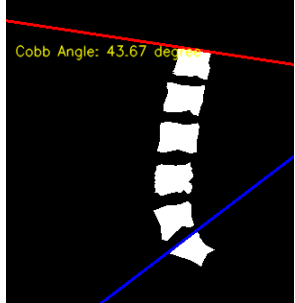
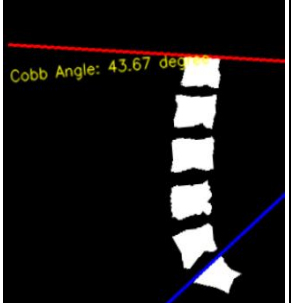
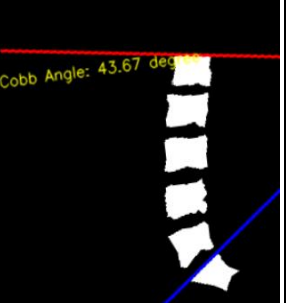

Le prétraitement des données est utilisée pour modifier le dataset , afin de l'adapter aux entrées de notre modèle CNN , voici quelques étapes de prétraitement de données.

IV.3.4.1. Augmentation des données

■ Augmentation physique

En utilisant un code python, nous avons crée un nouveau dataset augmenté de 2056 images a l'aide des méthodes d'augmentation trouvés dans la figure suivante :

Tableau IV.1. Les techniques d'augmentation de données appliquées aux images

Dataset Images	Rotation 5 ⁰ + zoom translation	Rotation 7 ⁰ + zoom translation	Rotation10 + zoom Translation
			

- **. Rotation**

La rotation d'une image consiste à faire pivoter l'image autour de son centre de manière à modifier l'orientation des objets présents dans l'image. La rotation permet de rendre le modèle invariant à l'orientation des objets.

Rotation de 5, 7 et 10 degrés : Ces petites rotations permettent de générer des variations subtiles de l'image d'origine. L'objectif est de permettre au modèle de mieux généraliser en apprenant à reconnaître les objets indépendamment de leur orientation.

- **Translation**

La translation d'une image consiste à déplacer tous les pixels d'une certaine distance dans une direction horizontale et/ou verticale. Cette technique aide le modèle à devenir plus robuste aux variations de position des objets dans l'image.

Translation de 20 pixels

Une translation de 20 pixels horizontalement et verticalement a été appliquée. Cela aide le modèle à apprendre que la position exacte de l'objet dans l'image n'est pas toujours fixe.

- **Zoom**

Le zoom sur une image consiste à agrandir ou réduire l'image en redimensionnant l'ensemble des pixels. Un zoom peut permettre au modèle de devenir invariant aux changements d'échelle.

- **Zoom de 0.1 (10%)** : Un zoom de 10% a été appliqué, ce qui signifie que l'image a été agrandie de 10%. Cela permet de simuler des variations d'échelle des objets dans les images.

- **Augmentation en temps réel :**

Image Data Generator

La classe ImageDataGenerator de la bibliothèque Keras (une API de haut niveau pour le développement et l'évaluation de modèles d'apprentissage profond, intégrée à TensorFlow). Cette classe est couramment utilisée pour effectuer des augmentations d'images en temps réel afin d'améliorer les performances de notre modèle CNN , les paramètres suivants ont été utilisés :

- **Rescale**

- **Description** : Ce paramètre normalise les valeurs des pixels des images. Les valeurs des pixels, habituellement comprises entre 0 et 255, sont redimensionnées pour se situer dans la plage [0, 1].

- **Raison** : La normalisation des valeurs de pixel accélère la convergence lors de l'entraînement du modèle en évitant des valeurs d'entrée trop grandes.

- **Shear Range**

- **Description** : La transformation de cisaillement (shearing) modifie la forme des images en déplaçant certains points de l'image sur un axe, avec une amplitude pouvant atteindre 20%.

- **Raison** : Le cisaillement rend le modèle plus robuste aux variations dans l'orientation des objets dans les images.
 - **Zoom Range** :
- **Description** : Ce paramètre permet de zoomer de manière aléatoire sur les images, avec une amplitude pouvant atteindre 20%.
- **Raison** : L'augmentation par zooming aide à rendre le modèle invariant à différentes échelles des objets dans les images.

Ces augmentations d'images sont appliquées pour générer des lots d'images augmentées à la volée pendant l'entraînement du modèle. Cela augmente artificiellement la taille du jeu de données d'entraînement et introduit des variations dans les images.

IV.3.4.2. Division du dataset

La répartition des données est une étape importante, consiste à diviser la base de données en un ensemble d'entraînement et de test, cette répartition est effectuée par un code Spyder. Dans ce cas, 70% du Dataset est consacré à l'entraînement, 20% au test et 10% pour la validation.

La base de données indique 1472 images pour l'entraînement, 416 images pour la validation et 168 images pour le test.

IV.3.5. Modèle 'Deteclordose'

IV.3.5.1. Architecture du modèle 'Deteclordose'

Ce modèle est une architecture de réseau de neurones convolutifs (CNN) spécifiquement développée pour la classification d'images en trois classes, cette architecture a été optimisée pour traiter des tâches de classification avec une précision élevée, tout en maintenant une efficacité de calcul élevée.




Figure IV.3. Architectue du modele 'Deteclordose'

Ce modèle comprend les couches suivantes

- Couches de convolution et de Pooling :

Le modèle comprend six couches de convolution et de pooling séquentielles, qui extraient progressivement des caractéristiques de plus en plus complexes de l'image d'entrée.

Chaque couche de convolution applique des filtres de taille 3x3 avec une activation ReLU, augmentant progressivement le nombre de filtres de 32 à 512 pour capturer des caractéristiques de plus en plus fines.

Les couches de pooling, utilisant des zones de 2x2, réduisent les dimensions spatiales après chaque convolution, diminuant ainsi la complexité et améliorant la l'efficacité du modèle. Cette architecture permet au modèle de détecter des caractéristiques importantes dans les images tout en réduisant la taille des données et en prévenant le surapprentissage.

- Couche d'aplatissement :

Cette couche convertit les données de sortie des couches convolutionnelles et de pooling en un vecteur unidimensionnel. Concrètement, l'aplatissement prend le tenseur 3D de dimensions (hauteur, largeur, canaux) produit par la dernière couche de pooling et le transforme en un vecteur 1D.


```
# Aplatir les données
flatten = Flatten()(pool2)
```

- Les couches entièrement connectées :

Couche dense1 qui crée une couche entièrement connectée avec 128 neurones, en utilisant la fonction d'activation ReLU pour introduire de la non-linéarité. Cette couche prend en entrée les données aplaties qui sont issues des couches de convolution et de pooling précédentes.

- Couche de décrochage (Dropout) avec un taux de chute de 50 % pour réduire le nombre de neurones utilisées de moitié, pour éviter le problème de surajustement.

```
# Couche complètement connectée
dense1 = Dense(128, activation='relu')(flatten)
dropout = Dropout(0.5)(dense1)
```

- Couche de sortie (Dense) :

couche de sortie avec trois classes (classification multiclass). L'activation softmax est utilisée pour cette couche finale, ce qui est approprié pour une tâche de classification multiclass.

```
# Couche de sortie
outputs = Dense(3, activation='softmax')(dropout)
```

IV.3.5.2. Paramètres d'entraînement

Pour avoir des meilleurs résultats et plus d'efficacité, nous avons choisis les **paramètres d'entraînement** suivants :

- L'optimiseur Adam (Adaptive Moment Estimation) :

Un algorithme d'optimisation couramment utilisé dans l'entraînement des réseaux neurones, en particulier dans le domaine de l'apprentissage profond.

L'optimiseur Adam s'adapte automatiquement aux taux d'apprentissage individuels pour chaque paramètre du modèle, ce qui peut accélérer la convergence de l'entraînement et aider à éviter les problèmes de déséquilibre dans les gradients.

- La fonction de perte (categorical_crossentropy) :

fonction de perte calcule l'erreur entre les prédictions du modèle et les étiquettes réelles en utilisant la formule de l'entropie croisée, ce qui en fait un choix courant pour les problèmes de

classification multiclasse. Elle mesure la divergence entre la distribution de probabilité prédite par le modèle et la distribution réelle des classes.

- Le nombre d' Epoches

Le nombre d'époques spécifié pour l'entraînement d'un modèle détermine combien de fois l'algorithme d'apprentissage passera sur l'ensemble de données d'entraînement complet. Dans ce contexte, 200 époques ont été spécifiées pour l'entraînement initial .

- Early Stopping

L'Early stopping est une technique qui permet de terminer l'entraînement plus tôt si la performance sur l'ensemble de validation cesse de s'améliorer après un certain nombre d'époques consécutives (200 epochs dans notre cas) . L'early stopping aide à prévenir le surapprentissage (overfitting) en arrêtant l'entraînement lorsque le modèle commence à trop bien s'adapter aux données d'entraînement

L'Early stopping peut intervenir avant la fin de ces 200 époques si la performance sur l'ensemble de validation cesse de s'améliorer. Par conséquent, le choix du nombre d'époques peut être guidé par l'observation de la performance du modèle au cours de l'entraînement .

IV.4. Résultats

IV.4.1. Résultats du modèle Dense Net 121

Ces résultats ont été obtenus après avoir entraîné le modèle pendant 200 époques qui ont été stoppées a 34 époques par l'Early Stopping afin d'éviter le surapprentissage du modèle . L'entraînement a pris environ 110 secondes pour chaque époque , 1h3min pour le processus complet.

- Accuracy & Loss




Figure IV.4.1 Évolution de la Précision et de la Perte du Modèle DENSENET121 au Cours de l'Entraînement et de la Validation"

Le graphique de gauche présente l'exactitude du modèle pour les ensembles d'entraînement et de validation. Nous pouvons observer que l'exactitude du modèle augmente rapidement dans les premières époques, passant d'environ 40% à 70% pour l'entraînement et 80% pour la validation. Cela indique que le modèle apprend efficacement dès le début. Ensuite l'exactitude continue d'augmenter mais avec des fluctuations. Le modèle atteint environ 80-85% d'exactitude pour l'entraînement et la validation. Vers la fin de l'entraînement l'exactitude de validation atteint un max de 87% . Il est notable que l'exactitude de validation dépasse souvent celle des données d'entraînement, ce qui pourrait indiquer une bonne généralisation du modèle.

Le graphique de droite montre la perte du modèle pour les ensembles d'entraînement et de validation. Initialement, la perte diminue rapidement, indiquant que le modèle apprend rapidement au début de l'entraînement. La perte passe de 7 à environ 1 pour l'entraînement et encore plus bas pour la validation. Par la suite, la perte continue de diminuer et se stabilise autour de 0.5 pour l'entraînement et un peu moins pour la validation. Dans les dernières époques, la perte reste stable avec de petites fluctuations, indiquant que le modèle a atteint un plateau en termes d'amélioration.

- Matrice de Confusion

Nous voyons sur la figure ci-dessous les prédictions sur l'ensemble de test ,91 images ont été correctement prédites et 101 ont été incorrectement prédites dans la classe des 'Hyper' contenant un total de 192 images , 52 images ont été correctement prédites et 48 ont été incorrectement prédites dans la classe des 'Hypo' contenant un total de 100 images , et 87 images ont été correctement prédites et 37 ont été incorrectement prédites dans la classe des 'Normal' contenant un total de 124 images .

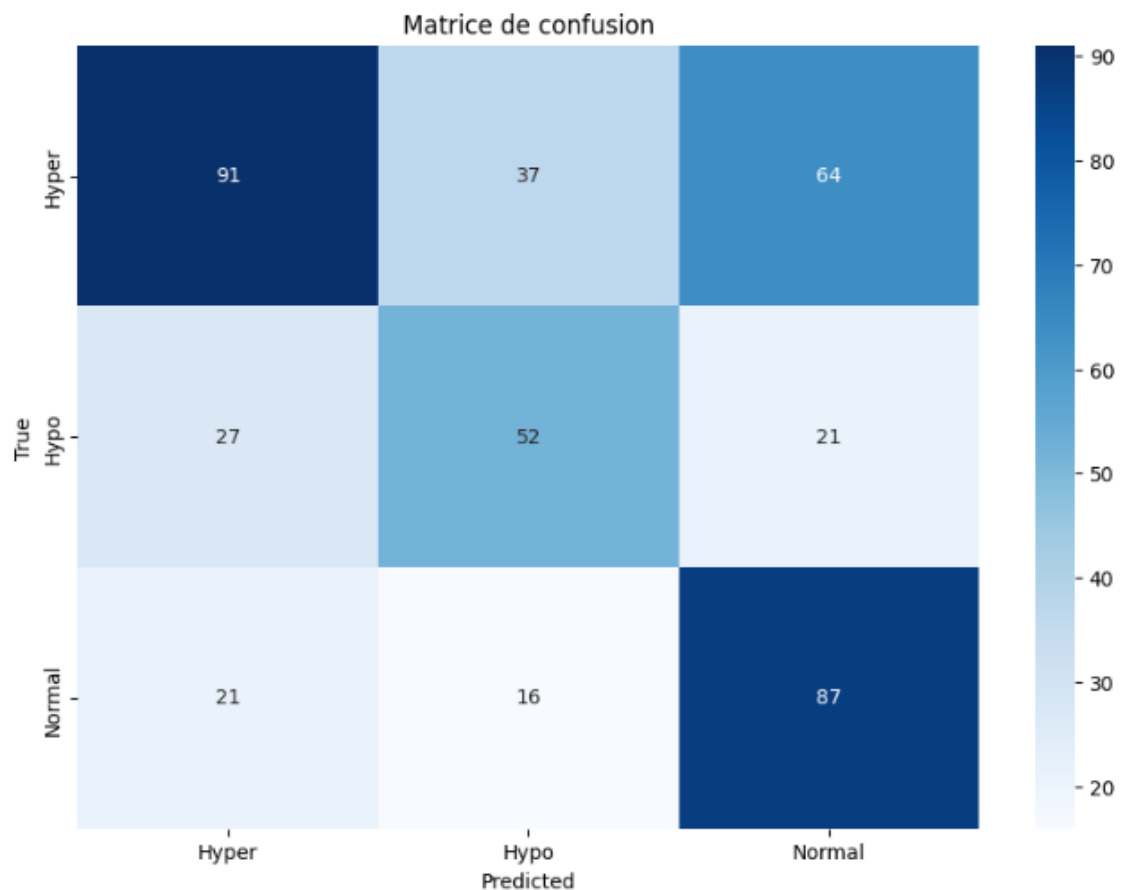


Figure IV.4.2 Matrice de confusion du modèle DenseNet121

La matrice de confusion révèle que le modèle n'est pas encore parfait et a du mal à différencier certaines classes. Une analyse plus approfondie et des améliorations de l'approche de modélisation sont nécessaires pour obtenir une meilleure précision globale.

IV.4.2. Résultats du modèle VGG 19

Ce modèle a été entraîné sur 40 époques qui ont été arrêtés sur 40 époques par l'early stopping pour éviter le surapprentissage du modèle, chaque époque a pris 80 secondes avec un total d'entraînement de 54 min

- Accuracy & Loss




Figure IV.4.2.1 Évolution de la Précision et de la Perte du Modèle VGG19 au Cours de l'Entraînement et de la Validation"

Le graphique gauche montre la courbe d'exactitude pour l'entraînement et la validation sur 40 époques. L'exactitude augmente rapidement au début, ce qui indique une bonne phase d'apprentissage initial. Après environ 10 époques, l'exactitude de l'entraînement continue à augmenter progressivement, atteignant environ 80 %. L'exactitude de la validation fluctue plus que celle de l'entraînement mais reste globalement supérieure, atteignant environ 85 % à son maximum. Ces fluctuations indiquent une variation normale lors de l'évaluation sur des lots de validation différents .

Le graphique droit illustre la courbe de perte pour l'entraînement et la validation sur 40 époques. Initialement, la perte diminue rapidement, indiquant un apprentissage efficace. Après environ 10 époques, les pertes se stabilisent autour de 0.5, montrant que le modèle converge. Les courbes de perte d'entraînement et de validation restent proches, suggérant une bonne généralisation sans surapprentissage significatif.

- Matrice de Confusion

La figure ci-dessous représente la matrice de confusion les performances de classification du modèle sur les classes "Hyper", "Hypo" et "Normal". 87 images de la classe "Hyper" ont été correctement classées, tandis que 40 images ont été classées comme "Hypo" et 65 images comme "Normal". Pour la classe "Hypo", seulement 41 images ont été correctement classées, 33 images ont été classées comme "Hyper" et 26 images comme "Normal". Et pour la classe "Normal", 84 images ont été correctement classées, 23 images ont été classées comme "Hyper" et 17 images comme "Hypo".




Figure IV.4.2 Matrice de confusion du modèle VGG19

Globalement, le modèle semble avoir des difficultés à différencier correctement les classes, particulièrement pour la classe "Hypo". Le nombre élevé de fausses classifications indique qu'il y a encore de la place pour améliorer la précision du modèle.

IV.4.3. Résultats du modèle VGG 16

Ces résultats ont été obtenus après avoir entraîné le modèle pendant 200 époques qui ont été stoppées à 50 époques par l'early stopping afin d'éviter le surapprentissage du modèle. L'entraînement a pris environ 83 secondes pour chaque époque, 1h15min pour le processus complet.

- Accuracy & Loss

La figure ci-dessous représente les graphes d'exactitude et de perte pendant l'entraînement et la validation du modèle .




Figure IV.4.3.1 : Évolution de la Précision et de la Perte du Modèle VGG16 au Cours de l'Entraînement et de la Validation

À gauche, le graphique de la perte montre une diminution rapide et continue de la perte de l'entraînement (en rouge) et de la validation (en bleu), ce qui indique que le modèle s'améliore au fur et à mesure de l'entraînement. Les courbes se stabilisent vers la fin, suggérant que le modèle a bien convergé.

À droite, le graphique de l'exactitude montre que l'exactitude de l'entraînement augmente progressivement pour atteindre environ 0.85. L'exactitude de validation présente plus de variations mais tend également à augmenter, se stabilisant autour de 0.85 à 0.9. Les fluctuations de l'exactitude de validation suggèrent une certaine variance mais pas de surapprentissage significatif.

- Matrice de Confusion

La figure ci-dessous représente la matrice de confusion de ce modèle

La matrice montre la performance d'un modèle de classification pour trois classes : Hyper, Hypo et Normal. Le modèle a correctement prédit 109 instances de la classe Hyper, mais en a mal classé 39 comme Hypo et 44 comme Normal. Pour la classe Hypo, seulement 52 instances ont été correctement prédites, avec 27 erreurs en Hyper et 21 en Normal. Enfin, pour la classe Normal, 63 instances ont été correctement prédites, avec 35 erreurs en Hyper et 26 en Hypo.

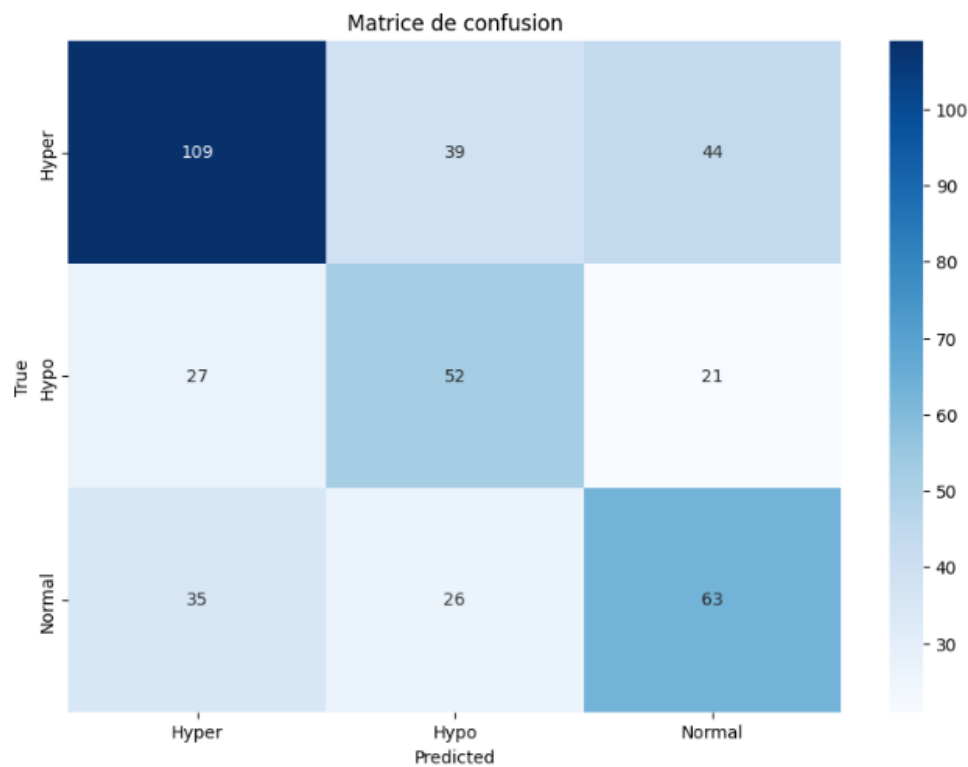


Figure IV.4.3.2 Matrice de confusion du modèle VGG16

Les résultats révèlent des difficultés du modèle à distinguer entre certaines classes, et peut être amélioré pour avoir de meilleurs résultats .

IV.4.4. Résultats du modèle ‘DetecLordose’

Ces résultats ont été obtenus après avoir entraîné le modèle pendant 200 époques qui ont été stoppées à sur environ 100 époques par l’early stopping afin d’éviter le surapprentissage du modèle . L’entraînement a pris environ 110 secondes pour chaque époque, 3 heures pour compléter l’entraînement.

IV.4.4.1. Accuracy & Loss

La figure ci-dessous représente les deux graphes d’exactitude et de perte :




Figure IV.4.4.1 : Évolution de la Précision et de la Perte du Modèle DETECLORDOSE au Cours de l'Entraînement et de la Validation

Le graphe de gauche affiche l'évolution de l'exactitude de l'entraînement et de la validation. L'exactitude de l'entraînement (en bleu) augmente de manière régulière pour atteindre environ 96 %. L'exactitude de la validation (en rouge) augmente rapidement dans les premières époques, atteignant environ 91 %, ce qui est un excellent résultat. Les fluctuations de l'exactitude de validation suggèrent une certaine variance mais pas de surapprentissage significatif.

Le graphe de droite montre la perte d'entraînement et de validation. La perte d'entraînement (en bleu) diminue de manière régulière pour atteindre environ 0,1, indiquant que le modèle apprend efficacement et minimise les erreurs. La perte de validation (en rouge) diminue rapidement au début et se stabilise autour de 0,2, ce qui est un signe de bonne généralisation aux données non vues.

IV.4.4.2. Matrice de Confusion :

La matrice de confusion montre les performances du modèle 'DetecLordose' de classification pour trois classes : "Hyper", "Hypo", et "Normal".




Figure IV.4.4.2 : Matrice de confusion du modèle DetecLordose

Pour la classe "Hyper", le modèle a correctement classé 172 instances. Il y a eu 1 instance incorrectement classée comme "Hypo" et 19 instances incorrectement classées comme "Normal". Pour la classe "Hypo", 96 instances ont été correctement classées. Cependant, 0 instances ont été incorrectement classées comme "Hyper" et 4 comme "Normal". Cela montre que le modèle a une bonne performance pour cette classe, mais il existe encore des erreurs à corriger. Pour la classe "Normal", le modèle a correctement classé 120 instances. Il y a eu 0 instances incorrectement classées comme "Hyper" et 4 comme "Hypo".

IV.5. Comparaison et discussion

IV.5.1. Comparaison des resultats

IV.5.1.1. Précision , Recall et F1 score

Le tableau présente les performances de quatre modèles différents pour une tâche de classification, évalués selon plusieurs métriques : exactitude, perte, précision, rappel et F1 score. Voici un bref commentaire sur les résultats :

Tableau IV.2. Tableau comparatif des performances des modèles

	Exactitude	Perte	précision	Recall	F1 score
DenseNet121	87%	50%	56%	56%	55%

VGG19	83%	45%	51%	52%	50%
VGG16	90%	25%	52%	53%	53%
DetecLordose	96%	10%	92%	94%	93%

- **DenseNet121** : Affiche une bonne exactitude de 87%, mais ses autres métriques de performance (précision, rappel, et F1 score) sont assez basses (environ 55-56%), indiquant une performance générale médiocre malgré une bonne exactitude.
- **VGG19** : Montre des performances globalement inférieures avec une exactitude de 83% et des scores de précision, rappel, et F1 score autour de 50-52%. La perte est de 45%, suggérant une efficacité modérée.
- **VGG16** : Obtient une meilleure exactitude de 90% avec des scores de précision, rappel, et F1 score légèrement supérieurs à ceux de VGG19 mais toujours faibles (autour de 52-53%). La perte est relativement basse à 25%.
- **DetecLordose** : Se distingue nettement des autres modèles avec une exactitude de 96%, des scores de précision, rappel et F1 score très élevés (92-94%, 93% respectivement), et une perte très basse de 10%, indiquant une performance supérieure sur tous les aspects évalués.

IV.5.1.2. Vrai Positifs

Le tableau 5.1.2 montre une Comparaison plus détaillées des Résultats de Détection de la Lordose en utilisant les matrices de confusion de chaque modèle

Tableau IV.3. Tableau de comparaison détaillée des performances des modèles

		Hyperlordose				Normal				Hypolordose			
		TP	FP	FN	TN	TP	FP	FN	TN	TP	FP	FN	TN
DeneNet 121		91	112	101	112	31	82	93	210	32	68	68	248
VGG19		87	56	105	168	84	91	40	201	41	57	59	259
Vgg16		109	62	83	162	63	65	61	227	52	65	48	251
Detect LORDOSE	0.3	178	3	14	221	113	17	11	275	96	9	4	307
	0.5	172	0	20	224	120	23	4	269	96	5	4	311

Analyse Comparée

- **DenseNet121 :**
Performances variées avec des FP et FN relativement élevés, indiquant des difficultés dans la classification correcte des classes Hyper et Hypo.
- **VGG19**
Meilleures performances que DenseNet121 pour certaines classes, mais encore des FP et FN assez élevés, surtout pour les classes Hyper et Hypo.
- **VGG16**
Performances légèrement améliorées par rapport à VGG19 et DenseNet121, mais encore des FP et FN importants.
- **DetecLordose**
- Performances nettement supérieures avec des TP très élevés et des FP et FN très faibles. La configuration avec dropout 0.5 montre une réduction encore plus marquée des FP, surtout pour la classe Hyper (FP = 0) et Normal (FP = 3).

5.1 Discussion

Les résultats indiquent clairement que le modèle Detect, en particulier avec un dropout de 0.5, surpasse les autres modèles en termes de toutes les métriques de performance. Cette supériorité est visible dans les valeurs plus élevées de précision, rappel et F1 score, ainsi que dans les tableaux de confusion qui montrent des erreurs minimales. Les modèles DenseNet121, VGG19 et VGG16, bien que performants dans certaines mesures comme l'exactitude, présentent des faiblesses significatives en termes de précision, rappel et F1 score, ainsi que des taux plus élevés de FP et FN.

IV.6. Conclusion :

Dans ce chapitre, nous avons présenté le développement détaillé et la comparaison de plusieurs modèles de classification pour la détection de la lordose à partir d'images IRM. Les résultats montrent que notre modèle personnalisé 'DetecLordose' offre des performances compétitives par rapport aux architectures préexistantes, avec des avantages spécifiques en termes de précision.

Cette comparaison souligne l'importance de choisir la bonne architecture et les bons paramètres d'entraînement pour optimiser les performances des modèles de deep learning dans des applications médicales.

Conclusion Générale

Le projet de fin d'études présenté ici démontre le potentiel des technologies de Deep Learning pour le diagnostic des pathologies lombaires à partir d'images médicales. Grâce à ce projet, nous avons développé le système 'DetecLordose', capable de classifier la lordose avec une précision notable. Les modèles explorés, incluant VGG16, VGG19 et DenseNet, ont chacun montré des performances variées, soulignant l'importance de sélectionner et de configurer correctement les architectures de réseaux neuronaux en fonction des spécificités des données médicales. L'utilisation de techniques d'augmentation des données et de prétraitement a également été nécessaire pour améliorer la performance et la généralisation des modèles. Les résultats obtenus mettent en lumière les avantages de l'apprentissage profond pour l'analyse d'images médicales, offrant des perspectives prometteuses pour l'amélioration des diagnostics cliniques. Cependant, des défis subsistent, notamment en termes de gestion des biais de données, de validation clinique et d'intégration dans les flux de travail médicaux.

Ce projet illustre comment les innovations technologiques peuvent transformer la pratique médicale, rendant les diagnostics plus précis et accessibles. Il ouvre la voie à de futures recherches et développements dans le domaine de l'intelligence artificielle appliquée à la santé, avec l'ambition d'améliorer encore davantage les soins aux patients et la qualité de vie des personnes souffrant de pathologies lombaires. Pour intégrer DetecLordose dans un environnement clinique réel, il est essentiel de sécuriser l'accès aux données médicales, de mettre en place un système informatique fiable et de développer une interface pour les professionnels de santé. Par exemple, cela pourrait inclure un accès sécurisé aux dossiers médicaux via une plateforme cloud et une interface simple où les médecins peuvent télécharger des images et recevoir des résultats de diagnostic instantanés. La validation clinique du modèle et la formation du personnel sont également essentielles pour garantir son adoption et son efficacité dans la pratique médicale quotidienne.

Une perspective prometteuse pour notre projet est d'entraîner notre modèle de deep learning sur des ensembles de données plus grands. L'utilisation de datasets plus vastes et diversifiés permettra à notre modèle d'apprendre de manière plus approfondie et de mieux généraliser à de nouvelles données, ce qui peut entraîner une amélioration significative de la précision et de la robustesse du modèle.

Nous envisageons également d'étendre notre modèle pour détecter d'autres anomalies ou pathologies vertébrales en utilisant des méthodes similaires. Cette détection multi-pathologies pourrait grandement bénéficier à la pratique clinique, en permettant un diagnostic plus complet et précis des patients.

En conclusion, ce projet met en évidence le potentiel transformateur de l'intelligence artificielle dans le domaine médical. En poursuivant les efforts de recherche et de développement, nous pouvons espérer améliorer encore davantage les diagnostics et les soins aux patients, en particulier pour ceux souffrant de pathologies lombaires

Bibliographie

Bibliographie

[1] « la-colonne-vertébrale-2022.pdf ». Consulté le: 20 juin 2024.

<https://facmed.univ-constantine3.dz/wp-content/uploads/2022/04/la-colonne-vertébrale-2022pdf.pdf>

[2] MKDO. Hernie discale, protrusion, discopathie. Consulté le: 20 juin 2024

<https://www.mkdo.lu/fr/hernie-discale/>

[3] « Rachis - Colonne vertébrale - Fiche Anatomie | la rhumatologie pour tous ». Consulté le: 27 mai 2024 <https://public.larhumatologie.fr/rachis-colonne-vertébrale-fiche-anatomie>

[4] : Dessin Michel Saemann - Archives Larousse Vertèbres cervicales. Consulté le 21 juin 2024 https://www.larousse.fr/encyclopedie/images/Vert%C3%A8bres_cervicales/1001412

[5] : Lakna. (2018, January 10). Difference between cervical and thoracic vertebrae. Pediaa. Consulté le 21 juin 2024 <https://pediia.com/difference-between-cervical-and-thoracic-vertebrae/>

[6] : Vikidia. (2021, février 5). Vertèbre. Vikidia. Consulté le 21 juin 2024

<https://fr.vikidia.org/wiki/Vert%C3%A8bre>

[7] : Hubert, J.-P. (n.d.). Le coccyx. J'aime les mots. Consulté le 21 juin 2024

<https://jaimelesmots.com/le-coccyx/>

[8] : « Rachis - Colonne vertébrale - Fiche Anatomie | la rhumatologie pour tous ». Consulté le: 27 mai 2024 <https://public.larhumatologie.fr/rachis-colonne-vertébrale-fiche-anatomie>

[9] : Cours-Médecine.info Le Rachis. Cours-Médecine.info. Consulté le 21 juin 2024,

<https://www.cours-medecine.info/medecine/anatomie/rachis.html>

[10] : Santé, P. (s.d.). Rachis lombaire. Consulté le 21 juin 2024

<https://www.passeportsante.net/fr/parties-corps/Fiche.aspx?doc=rachis-lombaire>

[11] : V. E. Casiano, G. Sarwan, A. M. Dydyk, et M. Varacallo, « Back Pain », in StatPearls, Treasure Island (FL): StatPearls Publishing, 2024. Consulté le: 8 juin 2024

<http://www.ncbi.nlm.nih.gov/books/NBK538173/>

[12] : M. Mousny, « Scolioses : définition, classifications, bilan clinique »

https://oer.uclouvain.be/jspui/bitstream/20.500.12279/203/1/Maryline%20Mousny_Scoliose_D%C3%A9finitions%20Classifications%20Bilan.pdf

[13] : Clinique Drouot. (s.d.). Scoliose - Opération possible. Consulté le 21 juin 2024,

<https://www.clinique-drouot.com/scoliose-operation-possible/>

[14] : « Hernie discale lombaire - Fondation Hopale ». Consulté le: 8 juin 2024

<https://www.fondation-hopale.org/fr/pathologie/hernie-discale-lombaire>

[15] : Dr. Georis Meyronet. La hernie discale. Consulté le 21 juin 2024

<https://www.drgeorismeyronet.com/la-hernie-discale/>

[16] : « LORDOSES OU CYPHOSES ? .pdf ». Consulté le: 8 juin 2024.

<https://kinedoc.org/work/kinedoc/45e459d2-5f4d-44ae-b076-f3bdb8086ae4.pdf>

- [17] : Freepik. Colonne vertébrale normale, lordose, cyphose, scoliose dans corps enfant - Illustration vectorielle plane. Consulté le 21 juin 2024, <https://fr.freepik.com/vecteurs-premium/colonne-vertebrale-normale-lordose-cyphose-scoliose->
- [18] : « Colonne vertébrale - Lordose - Hyperlordose - Hypolordose - Sténose ». Consulté le: 8 juin 2024 <https://orthochiro.ca/fr/lordose.php>
- [19] : « (PDF) Health-related quality of life in patients with low back pain in a low resource setting: a cross-sectional study at a tertiary hospital in Uganda ». Consulté le: 8 juin 2024. https://www.researchgate.net/publication/370043660_Health-related_quality_of_life_in_patients_with_low_back_pain_in_a_low_resource_setting_a_cross-sectional_study_at_a_tertiary_hospital_in_Uganda
- [20] « Low back pain ». Consulté le: 8 juin 2024. <https://www.who.int/news-room/fact-sheets/detail/low-back-pain>
- [21] : CEA, « Fonctionnement de l'IRM de diffusion », CEA/Médiathèque. Consulté le: 9 juin 2024 <https://www.cea.fr/multimedia/Pages/videos/culture-scientifique/sante-sciences-du-vivant/video-IRM-diffusion.aspx>
- [22] : Physimed. Imagerie par résonance magnétique (IRM). Consulté le 21 juin 2024, disponible sur <https://www.physimed.com/entreprises/imagerie-radiologie/resonance-magne/>
- [23] : L'Alsace. (2020, 19 novembre). Moins d'attente pour les IRM au centre de radiologie d'Illzach. L'Alsace. Consulté le 21 juin 2024 <https://www.lalsace.fr/sante/2020/11/19/moins-d-attente-pour-les-irm-au-centre-de-radiologie-d-illzach>
- [24] : Fonctions de la salle informatique. In IRM : Guide complet Consultee le 21 juin 2024 . <https://www.imaio.com/fr/e-mri>
- [25] : Commissariat à l'énergie atomique et aux énergies alternatives (CEA). Livret Imagerie Médicale. Consulté le 21 juin 2024 <https://www.cea.fr/multimedia/Documents/publications/livrets-thematiques/livret-imagerie-medicale.pdf>
- [26] : « Scanner (tomodensitométrie) - VIDAL ». Consulté le: 9 juin 2024.
- [27] : « Radiographies - Sujets particuliers », Manuels MSD pour le grand public. Consulté le: 9 juin 2024 <https://www.msmanuals.com/fr/accueil/sujets-particuliers/examens-d-imagerie-courants/radiographies>
- [28] : Stephanix. RAD Series E DREAM. Consulté le 21 juin 2024 <https://stephanix.com/produits/rad-series-e-dream/>
- [29] : « Echographe.com » Échographie : Le Guide Complet ». Consulté le: 9 juin 2024 <https://www.echographe.com/echographie/>
- [30] : Réseau d'imagerie médicale de la Capitale (RIMC). Échographie générale. Consulté le 21 juin 2024 <https://rimc.ca/services/echographie-generale/>
- [31] : C.-A. Azencott, « Introduction au Machine Learning ». https://cazencott.info/dotclear/public/lectures/IntroML_Azencott.pdf
- [32] : « Machine learning : définition et fonctionnement », Talend - A Leader in Data Integration & Data Integrity. Consulté le: 10 juin 2024 <https://www.talend.com/fr/resources/what-is-machine-learning/>

- [33] : L. D. Matteis, « Introduction à l'apprentissage ». <https://eduscol.education.fr/sti/sites/eduscol.education.fr/sti/files/ressources/pedagogiques/14512/14512-introduction-lapprentissage-automatique-ensps.pdf>
- [34] : A. Ng, « Machine Learning Yearning-Draft ». https://nessie.ilab.sztaki.hu/~kornai/2020/AdvancedMachineLearning/Ng_MachineLearningYearning.pdf
- [35] : Medium. (s.d.). A guide to supervised learning. Consulté le 21 juin 2024 <https://medium.com/@ngneha090/a-guide-to-supervised-learning-f2ddf1018ee0>
- [36] : « Machine learning : définition et fonctionnement », Talend - A Leader in Data Integration & Data Integrity. Consulté le: 10 juin 2024. <https://www.talend.com/fr/ressources/what-is-machine-learning/>
- [37] : « Définition | Deep Learning - Apprentissage profond ». Consulté le: 10 juin 2024. <https://www.futura-sciences.com/tech/definitions/intelligence-artificielle-deep-learning-17262/>
- [38] : « Dahmane - Analyse d'images par méthode de Deep Learning appl.pdf ». <https://theses.hal.science/tel-03022934>
- [39] : Bennett, C. (2018). Relations among AI, machine learning, and deep learning. Consulté le 21 juin 2024 https://www.researchgate.net/figure/Relations-among-AI-machine-learning-and-deep-learning-Bennett-2018_fig1_335442009
- [40] : Futura Sciences Deep learning. Consulté le 21 juin 2024 <https://www.futura-sciences.com/tech/definitions/intelligence-artificielle-deep-learning-17262/>
- [41] : Huán, T. (2018). Deep Learning with Python. Consulté le 21 juin 2024, disponible sur <https://tanthiamhuat.files.wordpress.com/2018/03/deeplearningwithpython.pdf>
- [42] : Litjens, G., Kooi, M. E., Bejnor, F. C., et al. (2016). A survey on deep learning in medical image analysis. **Medical Image Analysis** <https://www.sciencedirect.com/science/article/abs/pii/S13>
- [43] : { Stanford University. }. Consulté le 21 juin 2024 <https://med.stanford.edu/content/dam/sm/dbds/documents/biostats-workshop/s41591-018-0316-z.pdf>
- [44] : « Qu'est-ce qu'un réseau neuronal ? – Les réseaux neuronaux artificiels expliqués – AWS », Amazon Web Services, Inc. Consulté le: 10 juin 2024. <https://aws.amazon.com/fr/what-is/neural-network/>
- [45] : Smith, J. (2018). Structure de modèle de réseau de neurones artificiels. *ResearchGate*. Consulté le 21 juin 2024 https://www.researchgate.net/figure/Structure-de-modele-de-reseau-de-neurones-artificiels_fig5_322263283

[46] : Inside Machine Learning. Fonction d'activation : Comment ça marche ? Une explication simple. Inside Machine Learning.

<https://inside-machinelearning.com/fonction-dactivation-comment-ca-marche-une-explication-simple/>

[47] : ZDNet. Qu'est-ce que l'apprentissage profond ? Voici tout ce qu'il faut en savoir. ZDNet

. <https://www.zdnet.fr/pratique/qu-est-ce-que-l-apprentissage-profond-voici-tout-ce-qu-il-faut-en-savoir-39964504.htm>

[48] : IBM. (n.d.). Neural networks. IBM. Retrieved June 21, 2024, from

<https://www.ibm.com/fr-fr/topics/neural-networks>

[49]: Blent. (n.d.). CNN: Comment ça marche? Blent. Consultée le 21 juin 2024

<https://blent.ai/blog/a/cnn-comment-ca-marche>

[50] : Rhee, W. (2018). Convolutional Neural Network Architecture [Figure]. ResearchGate. Consultée le 21 juin 2024,

https://www.researchgate.net/figure/Convolutional-Neural-Network-Architecture-Rhee-2018_fig1_374885314

[51] : OCTO Technology. Classification d'images: Les réseaux de neurones convolutifs en toute simplicité. OCTO Technology. Consultée le 21 juin 2024

<https://blog.octo.com/classification-dimages-les-reseaux-de-neurones-convolutifs-en-toute-simplicité>

[52] : Bhatt, A. (2020, February 19). Max pooling, 1x1 convolutions, receptive field calculation. Anil Bhatt's Tech Blog. Consultée le 21 juin 2024

<https://anilbhatt1.tech.blog/2020/02/19/max-pooling-1x1-convolutions-receptive-field-calculation/>

[53] : All about pooling layers for convolutional neural networks (CNN). Medium. Consultée le 21 juin 2024,

<https://medium.com/imagescv/all-about-pooling-layers-for-convolutional-neural-networks-cnn-c4bca1c35e31>

[54] : Deep Learning based Vertebral Body Segmentation with Extraction of Spinal Measurements and Disorder Disease Classification. Biomedical Signal Processing and Control. Advance Online publication

https://www.researchgate.net/publication/355191764_Deep_Learning_based_Vertebral_Body_Segmentation_with_Extraction_of_Spinal_Measurements_and_Disorder_Disease_Classification

[55] : Anitha, J., & Murali, R. (2018). VGG-16 model architecture [Figure]. ResearchGate. Consultée le 21 juin 2024,

https://www.researchgate.net/figure/VGG-16-model-architecture_fig3_373003918

[56] : Patil, S., Thool, R., Kotecha, K., Tondare, D., & Choudhary, S. (2022). Efficient CNN architecture for COVID-19 disease detection based on X-ray images. *Computers*, 4(4), 1027-1040. Consultée le 21 juin 2024,

<https://www.mdpi.com/2624-7402/4/4/56>

[57] : Minaee, S., & Kalchbrenner, N. (2021). ResNet-18 architecture [Figure]. ResearchGate. Consultée le 21 juin 2024

https://www.researchgate.net/figure/ResNet-18-architecture-20-The-numbers-added-to-the-end-of-ResNet-represent-the_fig2_349241995

[58] : Feng, D. (2020). (a) Identity shortcut connections; (b) The structure of ResNet-34 [Figure]. ResearchGate. Consultée le 21 juin 2024

https://www.researchgate.net/figure/a-Identity-shortcut-connections-bThe-structure-of-ResNet-34_fig6_341158371

[59] : DenseNet-121 architecture [Image description]. Google Images. Consultée le 21 juin 2024

https://www.google.com/imgres?q=densenet121&imgurl=https%3A%2F%2Fmiro.medium.com%2Fv2%2Fresize%3Afit%3A1400%2F1*4kPpyvHv73ypzTvo6y8J9w.png

[60] : Performance metrics: Confusion matrix, precision, recall, and F1 score. *Towards Data Science*. Retrieved June 22, 2024, from

<https://towardsdatascience.com/performance-metrics-confusion-matrix-precision-recall-and-f1-score-a8fe076a2262>

[61] : Leung, K. Neural network architecture diagrams. github.com/kennethleungty/Neural-Network-Architecture-Diagrams. Retrieved July 4, 2024, from

<https://github.com/kennethleungty/Neural-Network-Architecture-Diagrams>