



## Mémoire de fin d'études

En vue de l'obtention du diplôme de Master recherche en Informatique

Option : Intelligence Artificielle

---

# La prédiction précoce de l'arthrose du genou en utilisant le Deep Learning

---

*Réalisé par :*

TARI Meriem

*Encadré par :*

Dr. ALOUI Soraya

Mr. AITMATEN Zahir

Mme. MAHEDI Tinhinane

*Soutenu le 02 juillet 2023, Devant le jury composé de :*

Mme. Nabila YOUNESSI : ESI - Présidente

M. Fateh BOUCHEBAH : ESI - Examineur

Promotion : 2022/2023

# Remerciements

En tout premier lieu, je remercie Dieu le tout-puissant, de m'avoir donné la santé et la force pour dépasser toutes les difficultés et terminer ce travail.

Je tiens à exprimer ma profonde gratitude envers ma directrice de mémoire **Mme. Aloui Soraya** pour sa guidance, son soutien, sa disponibilité et ses précieux conseils tout au long de ce processus de recherche.

J'adresse mes sincères remerciements à **M. Aitmaten Zahir** pour son soutien, ses précieux conseils, son expertise, ses orientations et sa disponibilité qui ont grandement contribué à l'aboutissement de ce travail de Recherche.

Je tiens à remercier ma co encadrante **Mme. Mahedi Tinhinane** pour son soutien, ses conseils et son expertise tout au long de ce projet.

Mes remerciements vont également à tous les membres de jury, pour avoir accepté de consacrer leur temps et leur expertise à l'évaluation de ce mémoire. Leurs commentaires et suggestions constructives vont enrichir mon travail et contribueront à sa qualité.

Je souhaite également adresser mes remerciements à mes collègues et amis qui m'ont soutenu et encouragé tout au long de ce parcours académique. Leurs échanges fructueux, leur collaboration et leur soutien moral ont été essentiels pour surmonter les obstacles et progresser dans ma recherches.

Enfin, je tiens à exprimer ma gratitude envers ma famille, mon mari et ma belle-famille pour leur amour, leur soutien indéfectible et leurs encouragements constants. Leur soutien inconditionnel a été une source d'inspiration et de motivation tout au long de ce mémoire.

# Dédicace

“

*Je dédie ce travail à ma mère, qui a été mon pilier et ma source d'inspiration tout au long de ma vie. Ton amour inconditionnel et ton soutien constant ont été mes plus grands atouts. Merci d'avoir été là à chaque étape de mon parcours, en m'encourageant et en me poussant à donner le meilleur de moi-même,*

*À mon père, dont l'intégrité et la détermination ont été des exemples inspirants. Ton soutien infaillible, tes encouragements et tes précieux conseils m'ont guidé sur le chemin de la réussite. Je vous aime de tout mon cœur et je dédie ce mémoire à vous, mes merveilleux parents,*

*À Ma chère sœur Imane et mes frères Ghillas et Youba, qui ont toujours été là pour moi. Je vous dédie ce mémoire en reconnaissance de notre amour fraternel qui ne cesse de grandir,*

*À mes amis, qui ont illuminé mon parcours académique de leur présence,*

*À mon cher mari, mon soutien inébranlable et mon partenaire de vie tout au long de cette aventure. Tu as été là à m'encourager à poursuivre mes rêves, me donnant la force de continuer même dans les moments les plus difficiles. Merci d'avoir cru en moi, de m'avoir soutenu sans relâche et d'avoir sacrifié tant de temps et d'efforts pour que je puisse me consacrer à mes études. Ce mémoire*

---

*est dédié à toi, pour tout ce que tu représentes dans ma vie  
et pour l'amour infini que nous partageons.*

*À ma belle-famille, pour votre soutien précieux et votre  
amour inconditionnel tout au long de ce parcours,*

*Merci pour tout !*

”

***Meriem***

# Table des matières

<b>Remerciements</b> . . . . .	<b>I</b>
<b>Dédicace</b> . . . . .	<b>II</b>
<b>Introduction générale</b> . . . . .	<b>1</b>
<b>1 Généralités</b> . . . . .	<b>4</b>
1.1 Introduction . . . . .	5
1.2 L'arthrose . . . . .	5
1.3 Types d'arthrose . . . . .	5
1.4 La gonarthrose . . . . .	6
1.5 Facteurs favorisant la gonarthrose . . . . .	7
1.5.1 Gonarthrose primaire . . . . .	7
1.5.2 Gonarthrose secondaire . . . . .	8
1.6 L'anatomie du genou . . . . .	8
1.7 Structure de l'os . . . . .	10
1.7.1 Os cortical . . . . .	11
1.7.2 Os trabéculaire . . . . .	11
1.8 Les symptômes de la gonarthrose . . . . .	12
1.9 Diagnostic de la gonarthrose . . . . .	12
1.9.1 Sur le plan clinique . . . . .	12
1.9.2 Classification radiographique . . . . .	13
1.10 Les traitements de la gonarthrose . . . . .	14
1.11 Conclusion . . . . .	15
<b>2 Les domaines de l'intelligence artificielle</b> . . . . .	<b>16</b>
2.1 Introduction . . . . .	17
2.2 L'intelligence artificielle . . . . .	17
2.3 Les domaines de l'Intelligence artificielle . . . . .	17
2.4 Machine Learning (ML) . . . . .	18
2.4.1 Apprentissage supervisé (AS) . . . . .	18
2.5 Apprentissage non supervisé (ANS) . . . . .	18
2.5.1 Apprentissage avec renforcement (AR) . . . . .	19
2.5.2 Transfert Learning . . . . .	19
2.6 Les réseaux de neurones . . . . .	19
2.6.1 Le perceptron . . . . .	19
2.6.2 Le perceptron multicouche (PMC) . . . . .	21
2.7 Le Deep Learning (DL) . . . . .	23

2.7.1	Les optimiseurs . . . . .	24
2.7.2	Taux d'apprentissage $\alpha$ et optimisation . . . . .	26
2.7.3	Les fonctions Loss (Perte) . . . . .	26
2.7.4	Métriques . . . . .	26
2.7.5	Régularisation . . . . .	27
2.8	Les limites de RNP . . . . .	28
2.9	Solutions . . . . .	28
2.10	Réseau de neurone convolutif (CNN) . . . . .	29
2.10.1	L'architecture d'un CNN . . . . .	29
2.10.2	Modèles des CNNs . . . . .	33
2.11	Conclusion . . . . .	37
<b>3</b>	<b>Etat de l'art . . . . .</b>	<b>38</b>
3.1	Introduction . . . . .	39
3.2	Travaux connexes . . . . .	39
3.3	Analyse et comparaison . . . . .	41
3.4	Conclusion . . . . .	44
<b>4</b>	<b>Approche proposée . . . . .</b>	<b>45</b>
4.1	Introduction . . . . .	46
4.2	Contribution . . . . .	46
4.2.1	Collecte des données . . . . .	46
4.2.2	Sélection des ROI . . . . .	46
4.2.3	Prétraitement . . . . .	48
4.2.4	Répartition des données . . . . .	48
4.2.5	Sélection du modèle . . . . .	48
4.3	Conclusion . . . . .	50
<b>5</b>	<b>Réalisation . . . . .</b>	<b>52</b>
5.1	Introduction . . . . .	53
5.2	Expérimentation . . . . .	53
5.2.1	Dataset . . . . .	53
5.2.2	Environnement de développement . . . . .	54
5.2.3	Langage de programmation . . . . .	54
5.2.4	Bibliothèques de Python . . . . .	55
5.3	Les Résultats du travail précédent . . . . .	56
5.3.1	La méthode . . . . .	56
5.3.2	Les résultats . . . . .	56
5.4	L'approche proposée . . . . .	57
5.4.1	La première étape . . . . .	57
5.4.2	La deuxième étape . . . . .	61
5.4.3	La troisième étape . . . . .	65
5.5	Conclusion . . . . .	70
	<b>Conclusion générale . . . . .</b>	<b>71</b>
	<b>Résumé . . . . .</b>	<b>78</b>

Abstract . . . . . 79

# Table des figures

1.1	Différents types d'arthrose [28]	6
1.2	Articulation saine et arthrosique [29]	7
1.3	Fréquence de l'arthrose selon l'âge [31]	8
1.4	Anomalies morphologiques des genoux favorisant une arthrose [7]	8
1.5	L'anatomie du genou [5]	9
1.6	L'anatomie du genou [57]	10
1.7	La structure interne des grands os [38]	11
1.8	Illustration des modifications de l'articulation induite par l'arthrose [34]	14
1.9	Radiographies pour différents stades d'atteinte arthrosique [34]	14
2.1	Les domaines de l'Intelligence artificielle [39]	17
2.2	Scénario typique d'AR [56]	19
2.3	Neurone biologique et artificiel [49]	20
2.4	Le neurone formel [50]	20
2.5	Les fonctions d'activation [16]	21
2.6	Schéma d'un perceptron multicouche [54]	22
2.7	La propagation avant et arrière [13]	23
2.8	Le Deep Learning et les méthodes classiques [40]	23
2.9	Calcul des paramètres du modèle [25]	24
2.10	La descente de gradient [26]	24
2.11	Exemples de convergences pour différents Learning rate [26]	26
2.12	L'arrêt prématuré [11]	27
2.13	Architecture Convolutional (CNN) [9]	30
2.14	Processus de convolution [13]	30
2.15	Application des filtres sur les images a convolé [13]	31
2.16	La carte de caractéristique résultante de la convolution [13]	31
2.17	L'opération de Pooling [13]	32
2.18	Processus de Max-Pooling [9]	32
2.19	L'opération de Pooling [32]	33
2.20	Le modèle LeNet [14]	34
2.21	Le modèle AlexNet [14]	34
2.22	Les modèles VGG [47]	35
2.23	Le modèle InceptionNet [14]	35
2.24	Bloc résiduelle avec une connexion de saut [14]	36
2.25	Le modèle DenseNet [24]	37
4.1	A. séparation automatique des genoux B. séparation automatique du fémur et tibia [58]	47



4.2	Détection du plateau tibiale [58]	47
4.3	Sélection des ROI [58]	48
4.4	Binary_accuracy [46]	50
5.1	<b>A.</b> Patchs des contours (tibia + fémur), <b>B.</b> Patchs du contour extérieur du tibia et <b>C.</b> Patchs du contour intérieur du tibia [59]	56
5.2	Les résultats de précision sur les différentes tailles des ROIs [59]	57
5.3	Quatre contours concaténés	57
5.4	L'entraînement de différents modèles	59
5.5	Les résultats du VGG16	59
5.6	Les résultats du VGG19	60
5.7	Les résultats du ResNet152V2	60
5.8	Les résultats de l'InceptionV3	61
5.9	L'entraînement de VGG19 sur les quatre contours	62
5.10	Les résultats de VGG19 sur le C1	63
5.11	Les résultats de VGG19 sur le C2	63
5.12	Les résultats de VGG19 sur le C3	64
5.13	Les résultats de VGG19 sur le C4	64
5.14	L'entraînement de VGG19 sur les régions 1, 2, 3	65
5.15	L'entraînement de VGG19 sur les régions 4, 5	66
5.16	L'entraînement de VGG19 sur les régions 6, 7	66
5.17	Les résultats de VGG19 sur la R1	66
5.18	Les résultats de VGG19 sur la R2	67
5.19	Les résultats de VGG19 sur la R3	67
5.20	Les résultats de VGG19 sur la R4	68
5.21	Les résultats de VGG19 sur la R5	68
5.22	Les résultats de VGG19 sur la R6	68
5.23	Les résultats de VGG19 sur la R7	69
5.24	La région 3 la plus informative	69

# Liste des tableaux

3.2	Comparaison des travaux connexes . . . . .	43
5.1	Les résultats de la première méthode . . . . .	58
5.2	Les résultats de la deuxième étape en appliquant le VGG19 . . . . .	62
5.3	Les résultats de la troisième étape en appliquant le VGG19 . . . . .	65

# Liste des abréviations

<b>IA</b>	<i>Intelligence Artificielle</i>
<b>ML</b>	<i>Machine Learning</i>
<b>DL</b>	<i>Deep Learning</i>
<b>CNN</b>	<i>Convolutional Neural Network</i>
<b>OMS</b>	<i>Organisation Mondiale de la Santé</i>
<b>OA</b>	<i>OsteoArthritis</i>
<b>OAI</b>	<i>OsteoArthritis Initiative</i>
<b>ROI</b>	<i>Region Of Interest</i>
<b>JSN</b>	<i>Joint Space Narrowing</i>
<b>JSW</b>	<i>Joint Space Width</i>
<b>KL</b>	<i>Kellgren &amp; Lawrence</i>
<b>CR</b>	<i>Computed Radiography</i>
<b>IRM</b>	<i>Imagerie par Résonance Magnétique</i>
<b>ADAM</b>	<i>Adaptive Moment Estimation</i>
<b>LR</b>	<i>Learning Rate</i>

# Introduction générale

## Contexte

L'arthrose est l'une des affections les plus courantes des maladies articulaires qui affecte de manière significative la qualité de vie de millions de personnes dans le monde. L'une des formes les plus répandues de l'arthrose est l'arthrose du genou est considérée comme 11ème facteur d'invalidité [2], et touche 250 millions de personnes dans le monde [3]. Cette pathologie se caractérise par une dégradation progressive du cartilage qui recouvre les extrémités osseuses des articulations, qui affecte spécifiquement cette articulation majeure du membre inférieur. Cette maladie chronique entraîne une douleur, une raideur et une diminution de la fonction articulaire, et Il n'existe pas de traitement modificateur de la maladie.

Traditionnellement, l'arthrose du genou est diagnostiquée lorsque les symptômes deviennent évidents et que des dommages articulaires significatifs se sont déjà produits. Cependant, une prédiction précoce et précise de l'arthrose du genou peut permettre d'identifier les individus à risque avant même l'apparition des symptômes, et ainsi d'instaurer des interventions préventives et des traitements adaptés.

Au cours des dernières années, l'intelligence artificielle « IA » a émergé comme un outil puissant dans le domaine médical. Les méthodes d'IA, telles que l'apprentissage automatique et les réseaux de neurones, permettent d'analyser de grandes quantités de données et d'extraire des modèles complexes, souvent invisibles à l'œil humain. Dans le contexte de l'arthrose du genou, l'utilisation de l'IA offre une opportunité prometteuse pour prédire et diagnostiquer la maladie de manière précoce, en utilisant des données cliniques, des images radiologiques et d'autres facteurs de risque potentiels.

## Problématique

Pendant longtemps l'arthrose du genou est considérée comme une pathologie cartilagineuse, ses symptômes étant principalement une dégradation des cartilages articulaires. Cependant, les récents travaux de recherche dans ce secteur ont montré que cette atteinte des cartilages ne suffisait pas à décrire l'arthrose, et que l'arthrose induit des modifications physiologiques dans toute l'articulation touchée, et particulièrement dans l'os sous-chondral. Selon l'anatomie du genou, l'os sous-chondral est composé de l'os sous-chondral

cortical et trabéculaire.

La problématique qui met en évidence dans le cadre de notre travail est :

— Le déterminant textural de la gonarthrose est d’abord visible dans la texture de l’os sous-chondral cortical ou trabéculaire.

— L’arthrose du genou, son classement de KL, sur les radiographies X est semi-quantitatif, ce qui signifie que les experts peuvent différer dans leur évaluation, ce qui introduit une subjectivité et rend le diagnostic très difficile, nous tenterons de résoudre cette problématique par les technique de l’IA.

— Il faudra trouver un modèle DL qui répondra aux contraintes imposées par notre thème : la médecine étant un domaine critique qui relève de la vie d’un humain, nous devons effectuer une étude méticuleuse des méthodes à utiliser afin d’obtenir une bonne solution.

## Objectifs

L’objectif de ce mémoire est d’utiliser les algorithmes d’apprentissage automatique pour la prédiction précoce de l’arthrose du genou qui est un problème articulaire principalement causée dû à la diminution du cartilage, afin de réduire les risques de complication de cette maladie chronique sur la santé du patient.

En effet, notre projet consiste à une prédiction précoce de l’arthrose du genou, c’est-à-dire de permettre aux personnes de savoir s’ils ont le risque de développer une arthrose avec un taux de prédiction, et à déterminer si le déterminant textural de la gonarthrose est d’abord visible dans la texture de l’os sous-chondral cortical ou trabéculaire.

## Méthodologie de la recherche

**Étape de recherche et d’analyse :** qui établit une analyse approfondie de l’état de l’art des différentes approches proposées par les chercheurs dans le cadre de prédiction de l’arthrose du genou et qui fait une comparaison selon les performances des méthodes à partir des taux de précision.

**Étape d’identification du problème et de la proposition d’une solution :** qui permet de définir la problématique et la solution proposée.

**Étape d’implémentions et d’expérimentation du système proposé :** qui met en évidence le système proposé, son fonctionnement et son intérêt

# Organisation du mémoire

Ce mémoire est organisé comme suit :

—**Le premier chapitre**, nous présentons l’arthrose, ses différents types, et les généralités sur la gonarthrose ainsi que les différents facteurs de risque qui favorisent cette dernière, ses diagnostics, et ses traitements.

—**Le deuxième chapitre**, nous explorerons en détail les méthodes de l’intelligence artificielle y compris les fondements de Machine Learning, ainsi que les techniques avancées telles que les réseaux de neurones, Deep Learning et les réseaux de neurones convolutifs (CNN) qui jouent un rôle central dans la compréhension et la classification des images.

—**Le troisième chapitre**, nous établirons un état de l’art sur la prédiction précoce de l’arthrose du genou, qui représente une étude comparative des travaux connexes que nous avons abrégés, nous avons présentés ceci dans un tableau détaillé décrivant chaque approche, en suivant chaque travail par un bref paragraphe qui le résume.

—**Le quatrième chapitre**, portera une description détaillée de notre approche de prédiction de l’arthrose du genou, en utilisant les modèles des réseaux de neurones convolutifs (CNN), et plusieurs réglages d’hyper paramètres pour sélectionner un meilleur modèle qui fait une bonne classification.

—**Le cinquième chapitre**, dans ce dernier, nous décrirons les modèles utilisés, l’environnement, les outils ainsi que les résultats obtenus dans le cadre de la classification de la gonarthrose et la sélection de la région la plus informative.

# Chapitre 1

## Généralités

### 1.1 Introduction

L'arthrose est l'une des principales causes de réduction de mobilité chez les personnes âgées (>50ans) mais elle peut également toucher des personnes plus jeunes en raison d'une blessure antérieure ou d'une malformation articulaire. Parmi les formes les plus courantes d'arthrose la gonarthrose ou l'arthrose du genou.

La gonarthrose se caractérise par la dégradation progressive du cartilage articulaire qui recouvre les aboutissants des os du genou. Elle a un impact significatif sur la qualité de vie des patients et peut entraîner des complications graves telles que la limitation fonctionnelle, la dépression et la perte d'indépendance. Les symptômes de la gonarthrose comprennent généralement (la douleur, une sensation de craquement...). En outre, il existe des facteurs de risque favorisant cette pathologie tels que le surpoids ou l'obésité...etc.

Ce chapitre a pour objectif de présenter une revue sur la gonarthrose, en se concentrant sur les facteurs de risque, les symptômes, les méthodes de diagnostic et les options de traitement disponibles.

### 1.2 L'arthrose

L'arthrose « OsteoArthritis 'OA' en anglais » est une maladie chronique dégénérative articulaire caractérisée par des douleurs mécaniques. Il s'agit de la pathologie articulaire la plus répandue [33]. L'OMS « Organisation Mondiale de la Santé » précise dans sa définition de l'arthrose "L'arthrose est la résultante de phénomènes mécaniques et biologiques qui déstabilisent l'équilibre entre la synthèse et la dégradation du cartilage, de l'os sous-chondral et de l'ensemble des tissus conjonctifs de l'articulation (synovial, ligaments, tendons, muscles, etc.) " [42].

### 1.3 Types d'arthrose

Il existe plusieurs types d'arthrose : L'arthrose cervicale, lombaire, du pouce, de la cheville, des épaules et du genou (Figure 1.1) [33].






FIG. 1.1 : Différents types d'arthrose [28]

Pour ce travail nous nous limiterons à l'arthrose du genou.

### 1.4 La gonarthrose

La gonarthrose ou l'arthrose du genou est la troisième forme d'arthrose la plus courante et l'une des plus invalidantes. Elle correspond à une usure de l'articulation par destruction progressive du cartilage. Les os du genou sont recouverts d'une fine couche de tissu cartilagineux qui fait office de tampon à la jointure des articulations. Lorsqu'il s'use, les os se frottent les uns contre les autres, d'où l'apparition de douleurs induisant la réduction de la mobilité [42]. 9 % des hommes et 18 % des femmes au-delà de 60 ans souffrent d'une arthrose symptomatique. La répartition est de 7 femmes pour 3 hommes. De plus en plus, des patients jeunes souffrent de lésions cartilagineuses importantes menant à moyen terme à une arthrose évoluée. La moyenne de durée de vie augmente d'année en année, ce qui a pour conséquence un plus grand nombre de patients concernés par la pathologie arthrosique (Figure 1.2) [10].

## Arthrose du genou

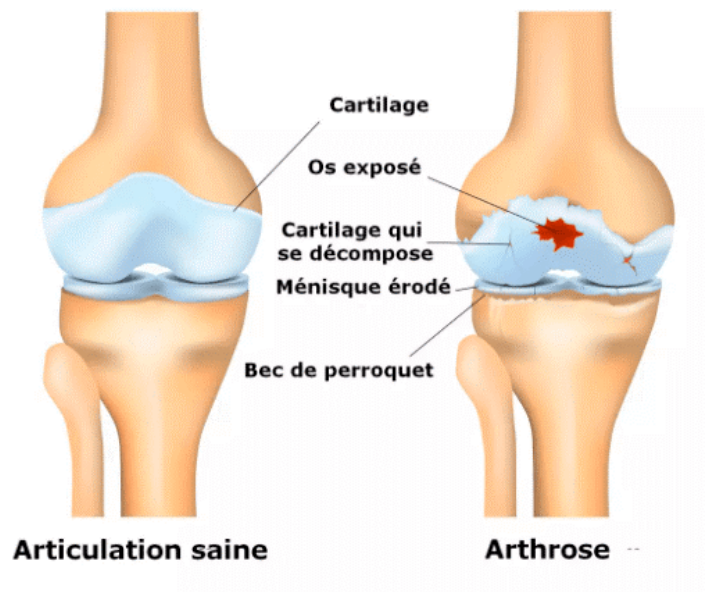


FIG. 1.2 : Articulation saine et arthrosique [29]

## 1.5 Facteurs favorisant la gonarthrose

### 1.5.1 Gonarthrose primaire

S'il n'existe pas de lésion préexistante de l'articulation touchée par l'arthrose. La gonarthrose primaire peut être favorisée par certains facteurs, comme :

- **La surcharge mécanique de l'articulation** : (surpoids, anomalie architecturale comme les dysplasies, surutilisation). Le surpoids et l'obésité sont vraiment les causes les plus fréquentes causant l'arthrose de genou.
- **Les anomalies du métabolisme** : (diabète...etc.)
- **Les troubles hormonaux** : (les femmes sont plus touchées après la ménopause au niveau des genoux).
- **Une prédisposition familiale** : (facteurs génétiques).
- Une faible activité physique.
- **Le vieillissement** : il y a une corrélation entre l'âge et l'augmentation de la fréquence de l'arthrose : 3% des moins de 45 ans sont touchés par l'arthrose, les 65 ans et plus sont environ 65% à en souffrir et après 80 ans, plus de 80% de la population s'en trouvent touchés (Figure 1.3) [12].

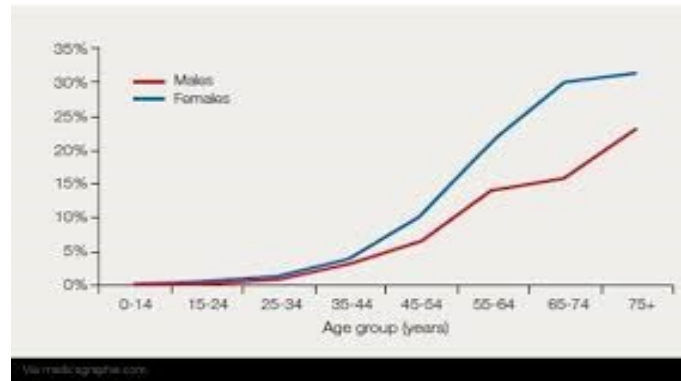


FIG. 1.3 : Fréquence de l'arthrose selon l'âge [31]

### 1.5.2 Gonarthrose secondaire

Si l'arthrose survient sur une articulation fragilisée par des lésions plus ou moins anciennes ou une maladie du cartilage [12] :

- **Malposition** : la désaxation des membres en genuvarum ou valgum (Figure 1.4) [ref5].




FIG. 1.4 : Anomalies morphologiques des genoux favorisant une arthrose [7]

- À la suite de blessures post-traumatique.
- **Maladies rhumatismales inflammatoires** : (polyarthrite rhumatoïde, arthrite psoriasique) [12].

## 1.6 L'anatomie du genou

Le genou est l'articulation la plus complexe du corps humain (Figure 1.5). Il constitue la jonction entre la partie haute et la partie basse de la jambe. Cette articulation est constituée de deux jointures placées côte à côte : la jointure fémoro-tibiale qui se situe entre le fémur et le tibia et la jointure fémoro-patellaire qui se trouve entre le fémur et la rotule [52].

Le genou est constitué de trois segments osseux : les condyles fémoraux, les plateaux tibiaux et la rotule [52]. Ces trois segments sont recouverts d'une fine couche de cartilage

articulaire. La structure physique du cartilage permet un glissement fluide et sans résistance entre les deux parties. Le cartilage assure ainsi la mobilité de l'articulation. Situé à chaque extrémité osseuse, le cartilage est un tissu à la fois résistant et élastique, véritable amortisseur, il absorbe les chocs et facilite la bonne mobilité de chaque articulation de notre corps [4].




FIG. 1.5 : L'anatomie du genou [5]

Le genou est composé de plusieurs éléments :

- **Des os du membre inférieur**

- Le bas du fémur (os de la cuisse).
- Le haut du tibia (os principal de la jambe).
- La rotule qui est un élément essentiel du genou. Sans celui-ci nous ne pouvons pas tenir debout sans que le genou fléchisse sous notre propre poids.

Ces 3 parties sont recouvertes de cartilage sur leurs surfaces de glissement.

Il existe ainsi 3 "sous-articulations" que l'on appelle compartiments :

- Fémoral-tibia médial (en dedans).
- Fémoro-tibial latéral (sur le côté).
- Fémoro-patellaire (entre la rotule et le fémur)

- **Les ligaments** : sont comme des cordes qui assurent la stabilité de l'articulation, sur les côtés les ligaments collatéraux, médial en dedans et latéral en dehors. Au milieu de l'articulation, entre les compartiment médial et latéral, se situent les ligaments croisés :

- Ligament croisé antérieur (LCA) le plus souvent touché dans les traumatismes.

- Ligament croisé postérieur (LCP) plus rarement atteint.
- **Les ménisques sont des fibrocartilages** : à la consistance de caoutchouc, qui permettent d'améliorer la congruence de l'articulation. En effet le fémur est arrondi et le tibia globalement plat. Il s'agit de tissus vivant mais peu vascularisé, ce qui explique leur difficulté à cicatriser naturellement. Ils ont une forme de croissant et sont triangulaires à la coupe.
  - Le ménisque médial se situe entre le fémur et le tibia, en dedans.
  - Le ménisque latéral se situe entre le fémur et le tibia, en dehors.
- **Une poche renforcée entoure l'articulation**  
Il s'agit de la capsule articulaire. Elle est tapissée à l'intérieur de membrane synoviale, qui sécrète le liquide synovial qui lubrifie l'articulation [6].

### 1.7 Structure de l'os

De par son contenu principalement minéral, l'os possède une grande rigidité. Cependant sa structure est complexe et guidée par les contraintes mécaniques qui lui sont appliquées. Sur le plan macroscopique, on peut le décrire comme un matériau « sandwich » composé d'une enveloppe dense « l'os cortical » et d'un cœur alvéolaire « l'os trabéculaire » (Figure 1.6). Ces deux éléments ont la même composition mais se distinguent par leur microstructure et leur organisation [34].

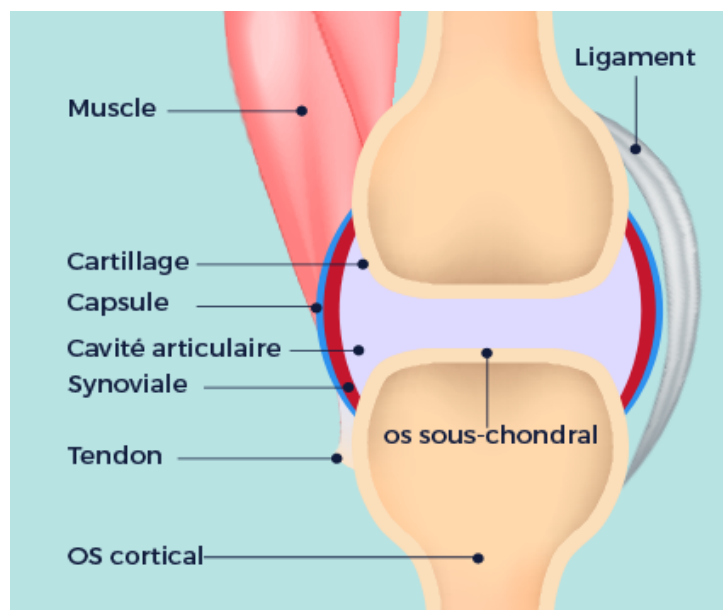


FIG. 1.6 : L'anatomie du genou [57]

### 1.7.1 Os cortical

L'os cortical ou os compact est un os dense avec une porosité inférieure à 5%, il compose la couche externe des os leur conférant leur rigidité. Cet os doit sa compacité à une agrégation concentrique de structures lamellaires autour d'un vaisseau sanguin formant des structures tubulaires appelées systèmes de Havers ou plus couramment ostéons. Ces ostéons visibles sur les agrandissements de la (Figure 6) sont orientés selon l'axe principal de l'os et soudés par leurs structures lamellaires composées d'ostéocytes. Ils assurent la protection et l'irrigation de la moelle osseuse via les canaux de Havers « vaisseaux au centre des ostéons » eux même interconnectés par des canaux transversaux « canaux de Volkmann ». Cet os cortical représente la forme majoritaire du tissu osseux dans le squelette avec près de 80% de la masse total [34].

### 1.7.2 Os trabéculaire

L'os trabéculaire aussi appelé os spongieux est caractérisé par sa microstructure poreuse semblable à une éponge. Il se retrouve majoritairement dans les os courts comme les vertèbres mais également au niveau épiphyses des os longs (Figure 1.7). C'est un matériau composite friable, constitué de travées osseuses ou trabécules qui servent d'armature à la matrice de moelle osseuse. Les trabécules, littéralement "petites poutres" en latin, sont des structures osseuses lamellaires en forme de poutre mais aussi de plaques interconnectées qui offrent un fort pouvoir de résistance à l'os face à un susceptible écrasement. Cette résistance peut cependant diminuer dans le cadre de pathologies osseuses comme l'ostéoporose qui vont fragiliser voire détruire ces travées, augmentant significativement le risque fracturaire. Cet os spongieux représente la forme minoritaire du tissu osseux dans le squelette avec 20% de la masse totale de celui-ci, pourtant elle couvre 60% de la surface totale des os. De plus l'activité métabolique au sein de l'os trabéculaire est 10 fois plus intense que dans l'os cortical [34].




FIG. 1.7 : La structure interne des grands os [38]

### 1.8 Les symptômes de la gonarthrose

Les symptômes de la gonarthrose est le problème majeur du point de vue des patients arthrosiques qui se répartie en deux phases :

- **Phase précoce de la maladie**

- Douleurs intermittentes avec phases de rémission.
- Phase de dérouillage.
- Douleurs de fatigue.
- Douleurs quand le patient monte un escalier.
- Brève raideur matinale.

- **Phase avancée de la maladie**

- Douleurs constantes.
- Tuméfactions/épanchements.
- Hyperthermie.
- Douleurs au repos/douleurs nocturnes.
- Raideur matinale plus longue (environs 30 à 60 min) [12].

### 1.9 Diagnostic de la gonarthrose

Contrairement à l'arthrite, la plupart des cas d'arthroses sont silencieux, c'est à dire que l'arthrose ne sera pas symptomatique et donc difficile à diagnostiquer. Il n'existe pas de marqueurs sanguins caractéristiques permettant de diagnostiquer la présence de l'arthrose même lors du gonflement de l'articulation. La prise de sang ou la ponction synoviale ne sont ainsi utiles que pour éliminer d'autres diagnostics [34]. Sur le plan clinique, les principales caractéristiques pathologiques de l'arthrose du genou sont le rétrécissement de l'espace articulaire, la formation d'ostéophytes et la sclérose. Ces marqueurs sont facilement visibles sur les radiographies. Malgré l'introduction de plusieurs méthodes d'imagerie telles que l'imagerie par résonance magnétique « IRM » et les échographies, les radiographies à rayons X ont toujours été préférées [8].

#### 1.9.1 Sur le plan clinique

En raison de la prévalence croissante de l'arthrose du genou, de la baisse de la qualité de vie liée à la santé et l'arthroplastie totale comme conséquence grave, il y a un besoin croissant d'outils cliniques et scientifiques efficaces pour la détection précoce de l'arthrose du genou, de manière fiable. L'identification précoce de l'arthrose du genou et l'évaluation de sa gravité sont cruciales pour le traitement de la pathologie, la prise de décision clinique, le diagnostic et le traitement [8]. Le diagnostic de la gonarthrose s'appuie généralement sur :

- Un examen clinique soutenu par un interrogatoire afin d'évaluer le type de douleur, la gêne ressentie ou encore la mobilité du genou.
- Des examens d'imagerie médicale pour évaluer l'état de l'articulation et préciser la nature de la gonarthrose [27].

### 1.9.2 Classification radiographique

Comme définie par l'OMS, l'arthrose se caractérise principalement par une dégradation du cartilage. Ces dégradations sont visibles par arthroscopie, cependant cette technique reste à la fois coûteuse et traumatisante. L'examen de référence pour l'arthrose reste ainsi la radiographie standard qui permet de visualiser l'interligne qui correspond à l'espace intra-articulaire ou Joint Space Width « JSW » en anglais. Ce pincement de l'interligne ou Joint Space Narrowing « JSN » correspond à une réduction du « JSW » résultant de la dégradation des cartilages et ménisques [34]. Cependant la mesure de cet interligne est conditionnée par le positionnement du patient lors de l'examen et sa reproductibilité reste limitée. Une autre limite de ce standard serait l'aspect tardif du phénomène observé puisque la diminution de l'interligne radiographique correspond à la conséquence de ces dégradations [34]. Les systèmes les plus couramment utilisés pour classer l'arthrose du genou sont les suivants :

- Comité international de documentation du genou (IKDC).
- Le système Ahlback.
- Le système Kellgren & Lawrence [8].

D'un point de vue plus général, la sévérité de l'arthrose est appréciée par les rhumatologues selon les critères définis par Kellgren & Lawrence (KL) en 1957. Cette échelle dispose de 4 stades pathologiques (Figure 1.8 et 1.9), et cette dernière est basée sur le pincement de l'interligne, la présence d'ostéophytes et la condensation de l'os sous-chondral [34].

Cette classification comporte cinq classes : articulation saine, arthrose douteuse, minimale, modérée et sévère [36].

- **Grade 0** - articulation saine.
- **Grade 1** - OA douteuse : pas de modification visible de l'articulation, présence d'ostéophytes non distincts.
- **Grade 2** - OA minimale : initiation du JSN avec présence d'ostéophytes distincts.
- **Grade 3** - OA modérée : JSN avec présence d'ostéophytes distincts.
- **Grade 4** - OA sévère : JSN avec ostéophytes nets et sclérose de l'os sous-chondral.






FIG. 1.8 : Illustration des modifications de l'articulation induite par l'arthrose [34]



FIG. 1.9 : Radiographies pour différents stades d'atteinte arthrosique [34]

## 1.10 Les traitements de la gonarthrose

Il n'existe pas de traitement définitif pour la gonarthrose. La prise en charge consiste à soulager les symptômes. Elle s'appuie sur un suivi médical régulier et peut être soutenu par :

- Le port d'orthèse, un appareillage qui va soutenir la fonction articulaire.
- L'usage d'une canne si nécessaire.
- Un accompagnement nutritionnel et diététique en cas de surcharge pondérale.
- Un traitement médicamenteux à base d'antalgiques pour soulager la douleur.
- La chirurgie en dernier recours avec la pose d'une prothèse du genou (dans le stade4) [27].
- Changement de mode de vie (Sport, Perte de poids, Arrêt du tabac, Physiothérapie et mesures orthopédiques...) [12].

## 1.11 Conclusion

Dans ce chapitre nous avons présenté la maladie d'arthrose, ses différents types et les généralités sur la gonarthrose ainsi que les différents modes de diagnostic de cette dernière.

Dans le chapitre suivant nous allons abordés quelques outils de Machine Learning qui peuvent aider les spécialistes dans leur diagnostic de la gonarthrose.

## Chapitre 2

# Les domaines de l'intelligence artificielle

### 2.1 Introduction

L'intelligence artificielle (IA) est un domaine en évolution continue qui repousse sans cesse les limites de ce que les machines peuvent accomplir. Grâce à l'IA, les ordinateurs peuvent effectuer des tâches complexes, résoudre des problèmes difficiles et même simuler des processus cognitifs humains tels que la perception, la compréhension du langage, la prise de décision et la classification des images. Et derrière cette apparente "intelligence" se cachent des méthodes sophistiquées qui permettent aux machines de traiter et d'analyser les données de manière automatique.

Dans ce chapitre, nous explorons en détail les méthodes de l'intelligence artificielle y compris les fondements de Machine Learning, ainsi que les techniques avancées telles que les réseaux de neurones, Deep Learning et les réseaux de neurones convolutifs (CNNs).

### 2.2 L'intelligence artificielle

L'intelligence artificielle (IA) désigne le processus de conférer à une entité artificielle « machine » la capacité de penser, de raisonner et même d'apprendre comme un être humain, en utilisant diverses théories et techniques [1].

### 2.3 Les domaines de l'Intelligence artificielle

L'intelligence artificielle (IA) englobe plusieurs domaines : machine Learning (ML) qui lui-même comprend Deep Learning (DL), ces trois concepts sont étroitement liés (Voir la figure 2.1) [1].




FIG. 2.1 : Les domaines de l'Intelligence artificielle [39]

Dans notre travail, nous allons nous intéresser sur le Deep Learning en particulier les (CNNs).

### 2.4 Machine Learning (ML)

Machine Learning (ML) ou "apprentissage automatique" est un domaine en plein essor de l'intelligence artificielle qui utilise des techniques statistiques pour donner aux ordinateurs la capacité d'apprendre et de faire des prédictions à partir des données [17].

L'apprentissage automatique peut être classé en trois grandes catégories :

#### 2.4.1 Apprentissage supervisé (AS)

L'AS consiste à fournir à l'ordinateur des exemples d'entraînement avec leurs sorties attendues, représentées par l'ensemble de données  $D$  :

$$D = \{x(1), y(1), (x(2), y(2)), \dots, (x(n), y(n))\} \quad (2.1)$$

L'objectif est de développer un modèle ou une fonction qui peut être utilisée pour prédire les sorties de nouvelles données, représentée par la fonction  $f : x \rightarrow y$ .

- Quand la sortie  $y$  est une valeur continue, cela s'appelle une régression.
- Quand  $y$  est discrète, cela s'appelle une classification [17].

Les principaux algorithmes d'apprentissage supervisé sont les suivants : forêts aléatoires, arbres de décision, algorithme KNN (k-Nearest Neighbors), régression linéaire, algorithme de Naïve Bayes, machine à vecteurs de support (SVM), régression logistique et boosting de gradient [60].

### 2.5 Apprentissage non supervisé (ANS)

L'objectif principal de l'ANS est de découvrir des motifs ou des structures cachées dans les données sans fournir d'étiquettes à l'algorithme [17].

$$D = \{x(1), x(2), \dots, x(n)\} \quad (2.2)$$

Il existe deux types d'apprentissage non supervisé :

- **Clustering** : l'objectif consiste à trouver des regroupements dans les données.
- **Association** : l'objectif consiste à identifier les règles qui permettront de définir de grands groupes de données.

Les principaux algorithmes d'ANS sont les suivants : K-Means, clustering/regroupement hiérarchique et réduction de la dimensionnalité [60].

### 2.5.1 Apprentissage avec renforcement (AR)

Le système apprend par des récompenses et des punitions données en retour aux actions du programme dans un environnement dynamique (Figure 2.2)[61].




FIG. 2.2 : Scénario typique d'AR [56]

### 2.5.2 Transfert Learning

Consiste à prendre des fonctionnalités apprises sur un problème et à les exploiter sur un nouveau problème similaire. Généralement, il est effectué pour les tâches où un jeu de données contient trop peu de données pour former un modèle à grande échelle à partir de zéro [61].

## 2.6 Les réseaux de neurones

Depuis longtemps, les scientifiques s'intéressent à comprendre le fonctionnement du cerveau humain. Le cerveau a d'énormes capacités pour effectuer des tâches complexes (la reconnaissance faciale, la classification des images...).

Les Réseaux de Neurones Artificiels (RNA) ont été introduits pour la première fois en 1943 par W. McCulloch et W. Pitts. Ils ont proposé un modèle simplifié de neurones biologiques capables de résoudre des problèmes de logique propositionnelle [16].

### 2.6.1 Le perceptron

Inventé en 1957 par F. Rosenblatt au laboratoire aérospatial de l'université de Cornell. C'est l'une des architectures de (RNA) les plus simples [16].

—Neurone biologique et artificiel

Le cerveau est composé de neurones reliés entre eux par des synapses. Il possède  $\sim 10^{11}$  neurones souvent organisés en couches, sous forme de vastes réseaux de neurones liés les uns aux autres (Figure 2.3).





FIG. 2.3 : Neurone biologique et artificiel [49]

Un neurone biologique est activé en fonction de l'intensité des signaux entrants. Peut-être imiter avec des fonctions d'activation [16].

—Le neurone formel



- ✓ Soit  $\sum_{i=1}^n \omega_i \cdot x_i = P$
- ✓ Si  $z \geq 0$  alors  $f(P) = 1$
- ✓ Si  $z < 0$  alors  $f(P) = 0$

FIG. 2.4 : Le neurone formel [50]

En tant qu'objet mathématique, le neurone reçoit un vecteur de données  $X$  (les dendrites) en entrée, qui est pondéré par des poids  $w$  (potentiels d'action/inhibition). Le centre du neurone formel représente la membrane cellulaire biologique où les messages

sont sommés. Pour modéliser cette sommation, une fonction mathématique de seuillage est utilisée (fonction d'activation). Le calcul est ensuite effectué de la manière montrée dans (Figure 2.4).

Les sorties 0 et 1 représentent chacune une classe de prédiction pour le vecteur d'entrée  $X$ . On dit alors que le perceptron est un classifieur binaire [45].

—**La fonction d'activation**

La fonction d'activation est utilisée pour transformer la somme pondérée des entrées d'un neurone en une valeur de sortie. Le biais agit comme un seuil, ou si la somme pondérée dépasse ce seuil, l'entrée de la fonction de transfert devient positive ou nulle, sinon elle est considérée comme négative. En conséquence, si la somme pondérée est inférieure au seuil, le neurone est inactif, s'il est proche du seuil, le neurone est en phase de transition, et s'il est au-dessus du seuil, le neurone est actif.

Il y a plusieurs types de fonctions d'activations qui peuvent être utilisés dans les (RNA) [35], Les principales fonctions d'activation  $\Phi$  sont : la fonction **sigmoïde**, **tangente hyperbolique (tanh)**, **tangente hyperbolique (tanh)**, **Leaky ReLU**, **Max out**, **ELU** (Figure 2.5) [62].




FIG. 2.5 : Les fonctions d'activation [16]

### 2.6.2 Le perceptron multicouche (PMC)

Dans les années 1980, de nouvelles techniques d'apprentissage des réseaux de neurones ont été proposées, notamment l'algorithme de rétropropagation du gradient. Cela a permis de développer des réseaux de neurones multi-couches, capables de résoudre des problèmes plus complexes.

Le Perceptron Multicouches (PMC) est un type de réseau de neurones dans lequel les neurones sont organisés en couches. Contrairement aux perceptrons simples, les (PMC) peuvent traiter des données qui ne sont pas linéairement séparables. Grâce à l'algorithme



de rétropropagation, les (PMC) sont aujourd'hui les réseaux de neurones les plus couramment utilisés. Il est composé de trois couches : la couche d'entrée, la couche intermédiaire « ou "couches cachées" » et la couche de sortie. Bien que l'utilité de plusieurs couches cachées n'ait pas été prouvée, le perceptron multicouche peut en comporter plusieurs. Dans une architecture complètement connectée, chaque neurone d'une couche est connecté à tous les neurones de la couche suivante. La (figure 2.6) illustre un exemple de (PMC) avec trois neurones d'entrées [62].




FIG. 2.6 : Schéma d'un perceptron multicouche [54]

### —L'algorithme de rétropropagation

L'algorithme de backpropagation est utilisé dans les réseaux de neurones pour entraîner un perceptron multicouche (PMC). L'objectif de l'apprentissage est de modifier les poids des connexions entre les neurones du réseau afin de minimiser la fonction de l'erreur par exemple, si on veut minimiser l'erreur quadratique moyenne la fonction est la suivante :

$$Erreur = \frac{1}{m} * \sum_{i=1}^n (y_i - y_j)^2 \quad (2.3)$$

Où n est le nombre de neurones de la couche de sortie. L'algorithme de rétropropagation fonctionne en deux phases (Figure 2.7) :

- **La première phase « forward »** : est la propagation vers l'avant, où les entrées sont propagées à travers les couches du réseau pour produire une sortie.
- **La deuxième phase « backward »** : est la rétropropagation de l'erreur, où l'erreur est calculée entre la sortie réelle et la sortie désirée, puis propagée en sens inverse à travers le réseau pour calculer les poids.

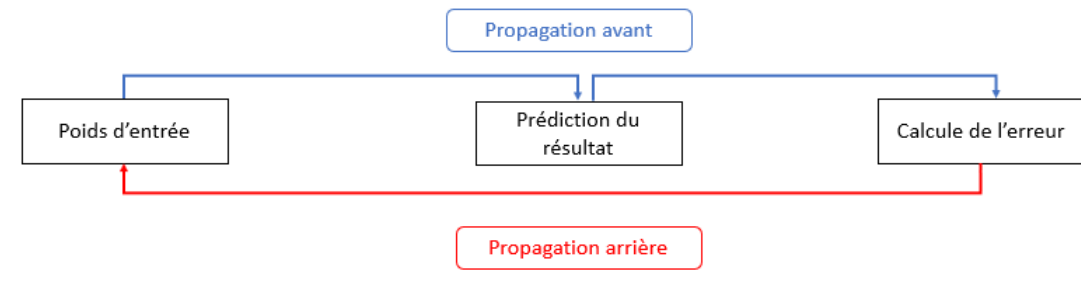


FIG. 2.7 : La propagation avant et arrière [13]

## 2.7 Le Deep Learning (DL)

Le DL désigne l'entraînement des réseaux de neurones très profonds, avec des dizaines de couches, chacune contenant des centaines de neurones, reliés par des centaines de milliers de connexions [18].

Les modèles de Deep Learning ont la particularité de fonctionner efficacement avec une grande quantité de données, alors que les modèles d'apprentissage automatique plus classique cessent de s'améliorer après un point de saturation (Figure 2.8).

Au fil des années, grâce à l'émergence du big data et des composants informatiques de plus en plus puissants, les algorithmes de DL, qui nécessitent beaucoup de puissance et de données, ont dépassé la plupart des autres méthodes. Ils semblent être capables de résoudre de nombreux problèmes, tels que la reconnaissance de visages, la classification d'images, la conduite de voitures autonomes ou encore la recherche de cellules cancéreuses [23].




FIG. 2.8 : Le Deep Learning et les méthodes classiques [40]

### 2.7.1 Les optimiseurs

Nous présenterons quelques algorithmes d'optimisation :

#### —Descente de gradient

Descente de gradient est une technique utilisée pour optimiser la fonction de coût ou l'erreur d'un modèle, visant à trouver la valeur minimale possible de l'erreur dans le modèle (Figure 2.10) [25], et il est calculé comme suit (Figure 2.9) :

$$\theta_i = \theta_{i-1} - \alpha * g$$

FIG. 2.9 : Calcul des paramètres du modèle [25]

$$g = \frac{\delta h_{\theta}(x)}{\delta \theta_i} \tag{2.4}$$

$\theta_i$  : les paramètres du modèle.

La fonction du coût à optimiser :

$$j(\theta) = \frac{-1}{m} [\sum_{i=1}^m y^{(i)} \log h_{\theta}(x^{(i)}) + (1 - y^{(i)}) \log(1 - h_{\theta}(x^{(i)}))] + \frac{\lambda}{2m} \sum_{j=1}^n \theta_j^2 \tag{2.5}$$

$\lambda$  : est considéré comme un hyper paramètre de régularisation.

$h_{\theta}$  : est la fonction du modèle.

$m$  : la taille du dataset d'apprentissage.




FIG. 2.10 : La descente de gradient [26]

### —Descente de gradient par lot

En utilisant la méthode de descente de gradient par lots « Batch », nous prenons en compte toutes les données d'entraînement pour effectuer une seule étape. Cela implique que nous calculons la moyenne des gradients pour tous les exemples d'entraînement et utilisons ce gradient moyen pour mettre à jour les paramètres. En d'autres termes, Il ne s'agit donc que d'une étape de descente de gradient à une époque [53].

Inconvénients :

- Lors de chaque mise à jour, il est nécessaire de parcourir l'ensemble complet des données d'entraînement afin de calculer la moyenne avant de mettre à jour un poids  $w$ .
- Le gradient par rapport à la somme de toutes les erreurs est trop grand, la mise à jour d'un poids devient alors conséquente et ne garantit pas l'accès à un poids optimale [45].

### —Descente de gradient stochastique (SGD)

La Descente de Gradient Stochastique est une solution aux inconvénients de Descente de Gradient par lot. Consiste à rechercher un poids optimal, en mettant à jour un paramètre à partir d'un seul exemple d'entraînement successive [45].

Inconvénients :

- Étant donné que la mise à jour des poids est effectuée pour un seul exemple d'entraînement, celle-ci devient excessivement sensible aux données individuelles.
- En conséquence, la convergence vers un minimum prend considérablement plus de temps.

### —La descente de gradient mini-batch

La méthode du mini-batch consiste à mettre à jour un poids en utilisant un lot de taille  $n$  exemples d'entraînement. Chaque itération complète sur l'ensemble des données représente une "époque" [45]. La mise à jour d'un poids comme suit :

$$w_1 = w_1 - \alpha \frac{\delta \sum_1^m \text{loss}(y_1, f(z_1))}{\delta w_1} \quad (2.6)$$

### —Adam optimizer

L'optimiseur Adam est une méthode de descente de gradient stochastique qui utilise une estimation adaptative des moments du premier et du second ordre. Selon [30], la méthode est " efficace en termes de calcul, nécessite peu de mémoire, est invariante au redimensionnement diagonal des gradients et convient bien aux problèmes de grande taille en termes de données/paramètres " [51].

### 2.7.2 Taux d'apprentissage $\alpha$ et optimisation

L'objectif de l'optimisation est de trouver les paramètres qui minimisent la fonction d'erreur. Il s'agit également de rechercher le taux d'apprentissage  $\alpha$  « Learning rate » optimal afin de converger rapidement et efficacement vers un  $w$  optimal. Le choix de cette valeur est souvent un défi car elle est considérée comme un hyper paramètre à ajusté de façon empirique. Si la valeur est trop petite, la réduction de l'erreur sera très lente, tandis que si elle est trop grande, des oscillations divergentes peuvent se produire. Soit la fonction de perte quadratique suivante (Figure 2.11) [45] :




FIG. 2.11 : Exemples de convergences pour différents Learning rate [26]

### 2.7.3 Les fonctions Loss (Perte)

Les fonctions de perte ont pour objectif de calculer la quantité que le modèle doit chercher à minimiser lors de l'apprentissage. Il existe plusieurs pertes :

- **Pertes probabilistes** : la fonction de perte calcule l'entropie croisée entre les étiquettes réelles et les étiquettes prédites, ce qui est couramment utilisé dans les applications de classification binaire où les étiquettes sont soit 0, soit 1.
- **Categorical Crossentropy** : la fonction de perte d'entropie croisée catégorielle est utilisée lorsque nous avons plus de deux classes d'étiquettes.
- **Binary\_crossentropy** : la cross-entropie binaire est une fonction utilisée pour mesurer la dissimilitude entre les prédictions d'un modèle et les véritables étiquettes dans un problème de classification binaire [41].

### 2.7.4 Métriques

Une métrique est une fonction utilisée pour évaluer les performances d'un modèle. Les fonctions métriques sont similaires aux fonctions de perte, à la différence que les résultats de l'évaluation d'une métrique ne sont pas utilisés pendant l'entraînement du modèle. Il existe plusieurs métriques tel que :

- **Binary Accuracy** : cette métrique calcule le taux de correspondance entre les prédictions et les étiquettes binaires.
- **Accuracy** : cette métrique calcule la fréquence à laquelle les prédictions correspondent aux libellés [46].

### 2.7.5 Régularisation

Cette technique fondamentale du Deep Learning a pour but de réduire le surapprentissage afin d'améliorer les performances. Il existe plusieurs formes de régularisation qui dépendent de l'objectif visé et des hypothèses formulées sur le problème. Parmi ces formes, on trouve des techniques telles que : le Dropout, l'arrêt prématuré (Early stopping), la régularisation L1, la réduction de poids (Weight decay) ou encore la régularisation L2 :

- **Dropout** : à chaque itération d'entraînement, chaque neurone (à l'exception des neurones de sortie) a une probabilité  $p$  d'être temporairement désactivé, ce qui signifie qu'il est complètement ignoré pendant cette itération d'entraînement, mais il peut être actif lors des itérations suivantes. L'hyperparamètre  $p$ , appelé taux de désactivation (dropout rate), est généralement fixé à 50% [15].
- **Early stopping** : Il est possible d'arrêter l'entraînement lorsque les performances du modèle sur l'ensemble de validation commencent à diminuer.

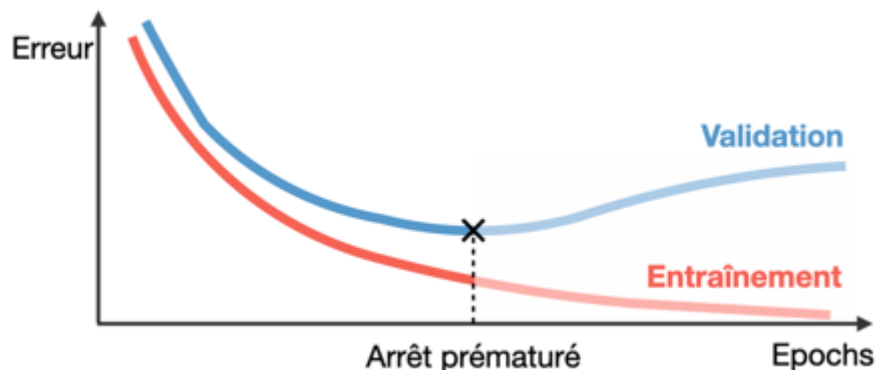


FIG. 2.12 : L'arrêt prématuré [11]

- **Régularisation L1 et L2** : un modèle avec moins de paramètres nécessite moins de puissance de calcul. Cependant, la réduction du nombre de paramètres n'est pas la seule solution pour simplifier un modèle. En réalité, les techniques de régularisation telles que L1 ou L2 permettent de limiter l'impact des poids dans les réseaux. Si les poids sont trop grands, ils peuvent avoir un impact négativement important. En revanche, s'ils sont trop petits, leur impact est faible [45].
- **Régularisation L1** : Dans la régularisation L1, au lieu de minimiser la Loss, on cherche à minimiser la formule suivante :

$$Loss_w(x, y) = Loss(x, y) + \lambda \sum_i |w_i| \quad (2.7)$$

$\lambda$  : est considéré comme un hyperparamètre de pénalité car plus il est grand plus les poids faibles sont réduits à zéro [45].

- **Régularisation L2 ou Weight decay** : Elle est obtenue en minimisant la fonction d'erreur tout en ajoutant un terme de pénalité qui correspond au carré des poids  $w$ , formulé de la manière suivante :

$$Loss_w(x, y) = Loss(x, y) + \lambda \sum_i w_i^2 \quad (2.8)$$

## 2.8 Les limites de RNP

L'entraînement d'un tel RNP n'est pas facile, car :

- Les couches inférieures du réseau sont difficiles à entraîner à cause des problèmes d'évanouissement ou d'explosion des gradients.
- L'entraînement est extrêmement lent.
- Un modèle comprenant des millions de paramètres risque fort de conduire au sur-apprentissage sur le jeu d'entraînement.

## 2.9 Solutions

Les solutions proposées pour les limites des RNP sont :

### —L'évanouissement et l'explosion de gradient

- Utilisation des techniques d'initialisation des poids de Xavier et de He.
- Utilisation d'un écrêtage de gradient (gradient clipping) : pour limiter l'explosion des gradients.
- Plusieurs variantes de ReLU ont été proposées : Leaky ReLU, Randomized Leaky ReLU, Parametric Leaky ReLU, ELU, et enfin SELU.

### —L'entraînement lent

- Réutiliser des couches pré-entraînées.
- Utilisés des algorithmes d'optimisation.

### —Eviter le surajustement

- Par la régularisation.

- **Augmentation de données** : la technique consiste à augmenter artificiellement la taille de l'ensemble de données en utilisant les instances d'entraînement existantes pour en générer de nouvelles, par exemple pour des images on peut appliquer diverses transformations telles que l'ajout de bruit blanc, des décalages légers, des rotations et des redimensionnements à chaque image du jeu de données, en ajustant l'ampleur des modifications. Ensuite, ces images résultantes sont ajoutées à l'ensemble de données d'entraînement [13].

## 2.10 Réseau de neurone convolutif (CNN)

En vision par ordinateur, les méthodes traditionnelles de classification d'images dont les caractéristiques sont extraites manuellement par des experts. Ces dernières sont ensuite sélectionnées de manière à ne garder que les plus pertinentes, puis utilisées dans des méthodes de classification. Cependant, cette tâche d'extraction et de sélection des caractéristiques peuvent être laborieuse, malgré le développement de nombreux descripteurs tels que le **SIFT** (Scale-invariant Feature Transform). La performance de ces méthodes traditionnelles repose largement sur la qualité des caractéristiques extraites.

En 2012, lors d'une compétition annuelle en vision par ordinateur, un nouvel algorithme de Deep Learning a établi de nouveaux records. Il s'agissait d'un réseau de neurones convolutifs (CNN). Ce dernier, reçoit des images en entrée, détecte automatiquement les caractéristiques de chaque image, puis entraîne un classificateur sur la base de ces caractéristiques [14].

### 2.10.1 L'architecture d'un CNN

L'architecture d'un CNN s'inspire du système visuel humain et utilise des couches de convolution pour extraire les caractéristiques importantes des données visuelles. Les couches de Pooling sont utilisées pour réduire la dimensionnalité des caractéristiques extraites. Enfin, les couches entièrement connectées effectuent la classification ou la régression des données en utilisant ces caractéristiques extraites (Figure 2.13).






FIG. 2.13 : Architecture Convolutional (CNN) [9]

—Couche de convolution

Une convolution, est le fait d'appliquer un filtre mathématique à une image . Explicitement, il s'agit de faire glisser une matrice par-dessus d'une image, et pour chaque pixel, utiliser la somme de la multiplication de ce pixel par la valeur de la matrice. Cette technique nous permet de trouver des parties de l'image qui pourraient nous être intéressantes (Figure 2.14) [14]. Dans une couche de convolution :

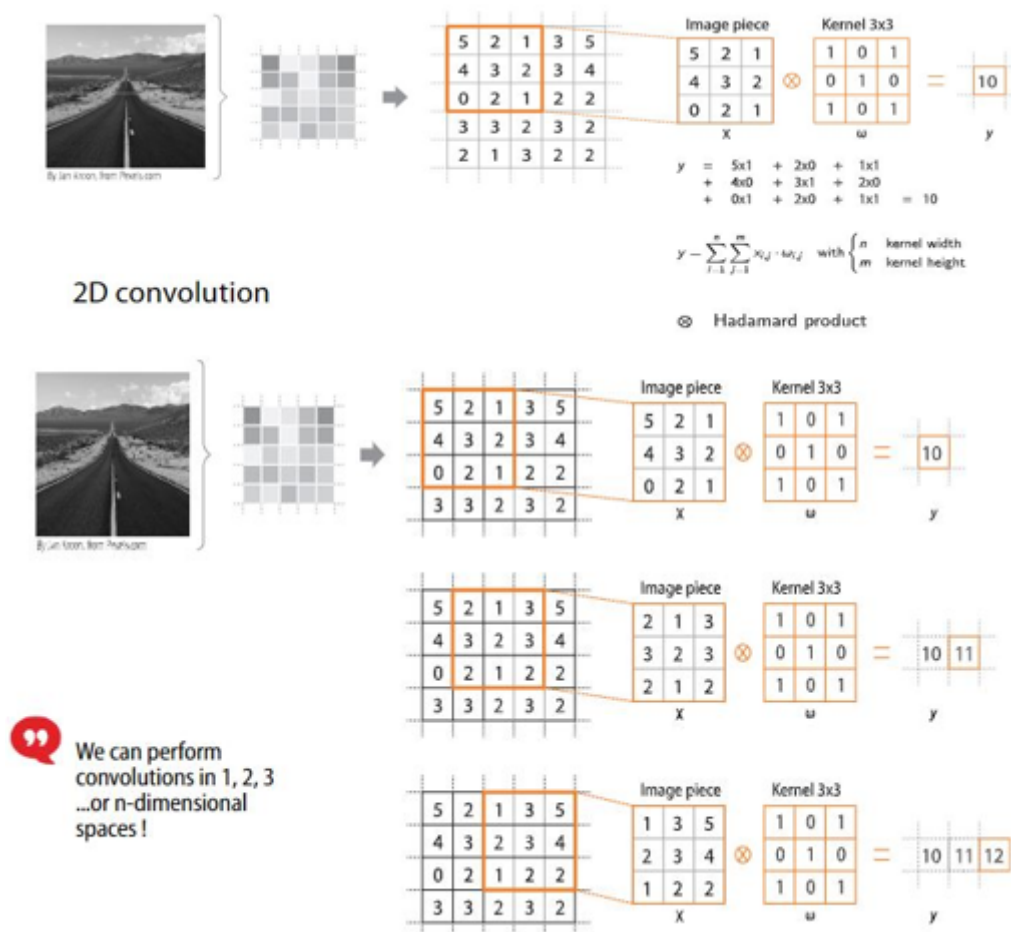


FIG. 2.14 : Processus de convolution [13]

- Plusieurs filtres sont appliqués, et chaque filtre possède une dimension égale à la dimension des données à convoluer (Figure 2.15).




FIG. 2.15 : Application des filtres sur les images a convolé [13]

- La convolution produit autant de nouvelles cartes de caractéristiques que de filtres de la couche.
- Lors de l'opération de convolution, la taille de la carte de caractéristique résultante est dépendante de deux paramètres : le **padding** et le **stride** (Figure 2.16).




FIG. 2.16 : La carte de caractéristique résultante de la convolution [13]

- Les filtres sont appris par le CNN lors la phase d'entraînement. Les noyaux des filtres désignent les poids de la couche de convolution. Ils sont initialisés puis mis à jour par rétropropagation du gradient [14]

### —Couche de Pooling

Son objectif est de réduire la taille de l'image d'entrée afin de diminuer la charge de calcul, l'utilisation de la mémoire et le nombre de paramètres. Cette opération utilise un filtre sans poids qui agrège les entrées en utilisant une fonction d'agrégation telle que la valeur maximale ou la moyenne (voir Figure 2.17) [14].

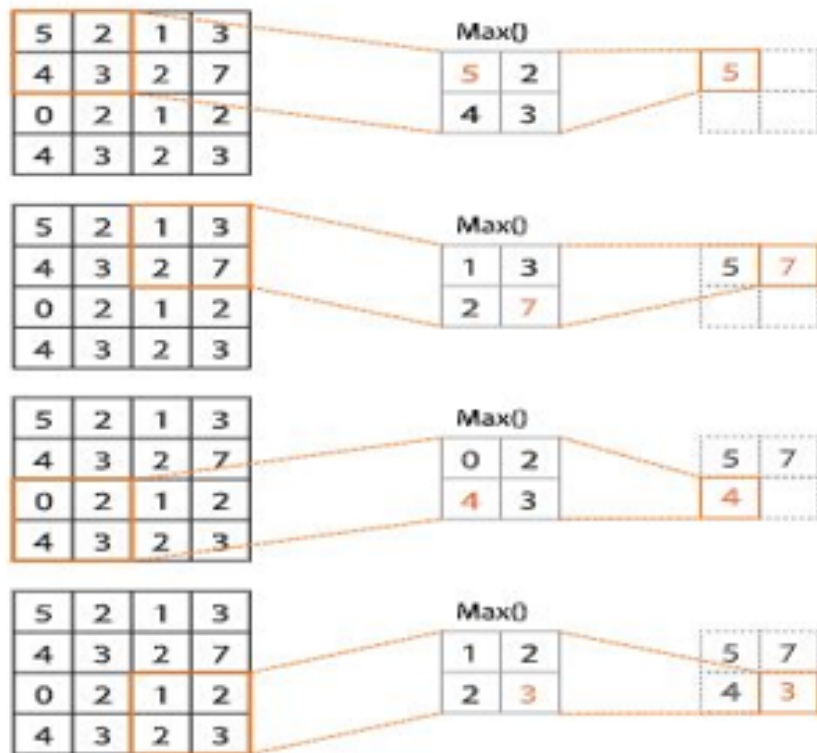


FIG. 2.17 : L'opération de Pooling [13]

Il existe deux types de Pooling :

- **Le Maximum Pooling** : divise la taille de l'entrée par 2 en prenant le maximum des carrés de taille 2 x 2 pixels (Figure 2.18).




FIG. 2.18 : Processus de Max-Pooling [9]

- **L'Average Pooling** : divise la taille de l'entrée par 2 en calculant la moyenne des carrés de taille 2 x 2 pixels. Le maximum Pooling est le plus utilisé surtout pour la reconnaissance des objets de grandes tailles et complexes [21].

### —Couche entièrement connectée (Fully- connected)

Elle est placée en haut de la pile pour effectuer la classification ou la régression des données (Figure 2.19). Les caractéristiques extraites des couches de convolution et de Pooling sont transmises à cette couche, qui les combine pour produire des prédictions ou des valeurs de sortie. Par exemple, dans une tâche de classification d'images, la couche entièrement connectée peut être utilisée pour assigner une probabilité à chaque classe possible.




FIG. 2.19 : L'opération de Pooling [32]

### 2.10.2 Modèles des CNNs

Il y a des réseaux qui ont prouvés leurs efficacités, notamment lors des compétitions organisées depuis 2010 sur une base de données d'images nommées ImageNet.

#### —LeNet

Proposé en 1998 par LeCun et al. LeNet est dédié à la classification de chiffres manuscrits et, aujourd'hui est une famille de 5 réseaux (de LeNet à LeNet-5) (Figure 2.20).

Nom	Type	Carte	Taille	Taille du filtre	Stride	Activation
Out	FC	-	10	-	-	Softmax
F6	FC	-	84	-	-	tanh
C5	Convolution	120	1*1	5*5	1	tanh
S4	Mean-Pooling	16	5*5	2*2	2	tanh
C3	Convolution	16	10*10	5*5	1	tanh
S2	Mean-Pooling	6	14*14	2*2	2	tanh
C1	Convolution	6	28*28	5*5	1	tanh
In	Entrée	1	32*32	-	-	-

FIG. 2.20 : Le modèle LeNet [14]

—AlexNet

Rempporte le défi ImageNet ILSVRC de 2012 avec un taux de reconnaissance de 84.6% (Figure 2.21).

Nom	Type	Carte	Taille	Taille du filtre	Stride	Padding	Activation
Out	FC	-	1000	-	-		Softmax
F9	FC	-	4096	-	-		ReLU
F8	FC	-	4096	-	-		ReLU
C7	Convolution	256	13*13	3*3	1	Same	ReLU
C6	Convolution	384	13*13	3*3	1	Same	ReLU
C5	Convolution	384	13*13	3*3	1	Same	ReLU
S4	Max-Pooling	256	13*13	3*3	2	Valid	-
C3	Convolution	256	27*27	5*5	1	Same	ReLU
S2	Max-Pooling	96	27*27	3*3	2	Valid	-
C1	Convolution	96	55*55	11*11	4	Same	ReLU
In	Entrée	3 (RVB)	224*224	-	-	-	-

FIG. 2.21 : Le modèle AlexNet [14]

—VGG (Visual Géométrie Group)

Le réseau utilise des petits filtres de taille (3x3). La simplicité du réseau se reflète dans sa composition qui comprend principalement des couches de regroupement et une couche entièrement connectée en tant que composants supplémentaires. VGG a introduit l'utilisation de piles de filtres (3x3) pour remplacer les filtres de taille (11x11) et (5x5). Cela a démontré que l'application simultanée de filtres de petite taille (3x3) peut produire des effets similaires à ceux des filtres de plus grande taille (5x5) et (7x7).

En réduisant le nombre de paramètres, l'utilisation de filtres de petite taille présente également l'avantage d'une faible complexité de calcul. Ces découvertes ont ouvert la voie à une nouvelle tendance de recherche dans les CNN, qui privilégie l'utilisation de filtres de taille réduite (Figure 2.22) [21].

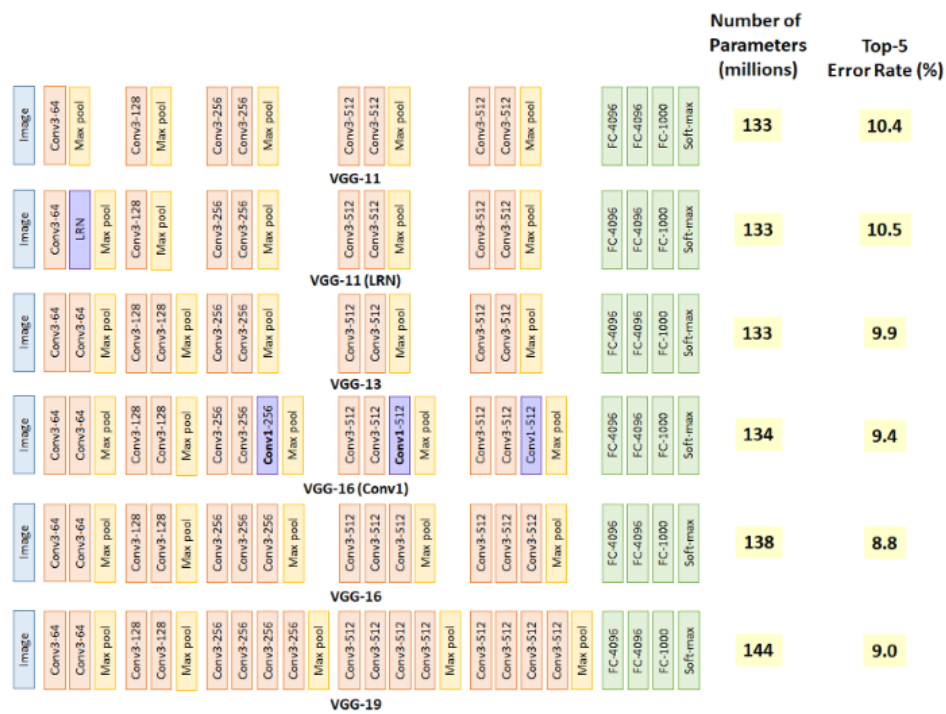


FIG. 2.22 : Les modèles VGG [47]

—GoogLeNet/InceptionNet

En remportant le défi ImageNet ILSVRC de 2014, GoogLeNet a réussi à réduire le taux d'erreur à moins de 7%. La principale raison de sa performance exceptionnelle réside dans sa profondeur accrue par rapport aux CNN précédents. Cette profondeur a été rendue possible grâce à l'utilisation de sous-réseaux appelés modules Inception, qui permettent à GoogLeNet d'utiliser les paramètres de manière beaucoup plus efficace que dans les architectures précédentes.

Le module Inception peut être considéré comme une couche de convolution capable de produire des cartes de caractéristiques identifiant des motifs complexes à différentes échelles. Cette approche a été essentielle pour améliorer la capacité du réseau à extraire des informations à des niveaux de complexité variés (Figure 5.8) [14].




FIG. 2.23 : Le modèle InceptionNet [14]

—ResNet (Residual Network)

Rempporte le défi ImageNet ILSVRC de 2015 en repoussant le taux d'erreur inférieur à 3.6%. ResNet est extrêmement profond (constitué de 152 couches). Pour entraîner un réseau aussi profond, l'astuce a été d'utiliser des connexions de saut (également appelées connexions de raccourcis, ou skip connexions) pour éviter le problème de disparition du gradient dans les couches profondes (Figure 2.24) [14].




FIG. 2.24 : Bloc résiduelle avec une connexion de saut [14]

—DenseNet

A été proposé pour surmonter le problème du gradient de fuite de la même manière que Highway Networks et ResNet. Étant donné que ResNet conserve expressément les informations via des transformations d'identité additives, de nombreuses couches peuvent fournir très peu ou pas d'informations. DenseNet utilise une connexion intercouche, bien que sous une forme modifiée, pour résoudre ce problème. Dans une approche par anticipation, DenseNet connecte chaque couche précédente à la couche suivante (Figure 2.25) [21].




FIG. 2.25 : Le modèle DenseNet [24]

## 2.11 Conclusion

Dans ce chapitre nous avons présentés en détail les différentes méthodes de l'intelligence artificielle tels que Machine Learning, les réseaux de neurones, Deep Learning ainsi que les réseaux de neurones convolutifs qui jouent un rôle central dans la compréhension et la classification des images.

Dans le chapitre suivant nous allons établir un état de l'art des principales approches relatives à la prédiction de la gonarthrose. Une étude comparative sera établie pour les principaux travaux déjà réalisés.



# Chapitre 3

## Etat de l'art

### 3.1 Introduction

L'arthrose du genou est l'une des principales causes de limitations des activités et d'incapacité physique chez les personnes âgées. Une détection et intervention précoce peuvent contribuer à ralentir l'aggravation de cette maladie.

Le classement des radiographies par des médecins, basé sur l'inspection visuelle est subjectif, varie selon les interprètes et dépend fortement de leur expérience. Grâce à l'intelligence artificielle, la santé est devenue de plus en plus simple à traiter ce qui facilite le diagnostic aux médecins, cela encourage les chercheurs à encore développer des systèmes intelligents, qui contribuent à une meilleure prédiction et détection de la gonarthrose.

La prédiction de la gonarthrose est le sujet le plus abordé par les chercheurs, tel qu'il existe plusieurs travaux proposés dans la littérature. Dans ce chapitre, nous présenterons les principaux travaux relatifs basés sur le thème posé et présenter les méthodes utilisées. Dans ces études ils ont utilisé la précision comme un facteur de comparaison entre les algorithmes d'apprentissage utilisés.

Il existe plusieurs méthodes de prédiction, nous verrons quelques-unes dans la synthèse des travaux connexes que nous allons voir dans ce chapitre et en effectuant une étude comparative entre ces derniers.

### 3.2 Travaux connexes

La prédiction précoce de la gonarthrose est cruciale pour aider les personnes âgées à ralentir la progression de l'arthrose et à améliorer leurs qualités de vie. Ci-dessous, nous allons présenter quelques travaux :

—**Yassine et al [48]** ont proposé une nouvelle approche pour la détection précoce de l'arthrose du genou, qui est l'Encodeur Automatique Régularisé Discriminatoire (**DRAE**). DRAE, est un modèle basé sur un auto encodeur dans lequel un terme de pénalité discriminatoire est ajouté, l'objectif est de forcer le modèle à apprendre des caractéristiques qui permet une meilleure classification. Ils ont extrait 5 régions d'intérêts (**ROI**) de taille  $32 \times 32$  sous le plateau tibial dans des radiographie X, uniquement les grades KL (0,1 et 2) sont introduit. D'abord, ils ont comparé cinq algorithmes d'apprentissage (support Vector machine avec la fonction de base radiales (**SVM-RBF**), Analyse Discriminante Linear (**LDA**), Softmax classifier (**SMC**) et le K-Nearest Neighbors (**KNN**)), ces algorithmes ont été exécutés dans le cas de classification binaires (KL 0 et 2) pour chaque région, la meilleure performance a été obtenue en utilisant le classificateur SVM-RBF avec une précision de (**82,53%**). Après, DRAE a été comparé à des modèles auto-encodeur basés sur l'apprentissage non supervisés (Auto-Encodeur (**AE**), Sparse-Auto-Encodeur (**SAE**)) en utilisant le classificateur SVM-RBF pour les grades KL (0 et 2) pour chaque région. Les résultats sont présentés en termes (d'exactitudes, de précision, de rappel et de F-mesure).

Les résultats obtenue en utilisant DRAE sont plus élevées que celles obtenues en utilisant AE et SAE, qui a atteint une précision de (**82,53%**). Enfin, le DRAE a également été comparé à des modèles des réseaux de neurones convolutifs telle que **ResNet-101** et **DensNet-121**. Le DRAE fournit des meilleures performances que le **ResNet-101** qui a atteint une précision de (**59,25%**) et le DensNet-121 a atteint (**71,67%**) de précision. En conclusion, les résultats montrent que le placement des ROIS, pourrait fournir des informations plus discriminantes, sur les changements de la microarchitecture osseuse dus à l'arthrose et conduire à une prédiction robuste.

—**Pingjun et al [20]** ont proposé un cadre de travail afin de développer un système qui peut effectuer une classification entièrement automatique du degré de gravité de l'arthrose du genou en utilisant les réseaux de neurones profonds et d'une nouvelle perte ordinale. Dans cette étude, ils ont appliqué deux réseaux de neurones convolutifs (**CNNs**). Le premier, consiste à détecter les articulations du genou à l'aide d'un réseau **YOLOV2** a un étage. Ensuite, un réglage fin est appliqué sur les **CNNs** les plus populaires (**ResNet**, **VGG**, **DenseNet** et **InceptionV3**) pour classer les images d'articulation du genou détecté avec une nouvelle perte ordinale ajustable. Pour la Détection, ils ont obtenu l'indices de Jaccard moyen (**IoU**) de 0,858 et un rappel (**Recalls**) de 92,2%. Et, pour la tâche de classification le modèle VGG19 finement réglé « fine-tuned » avec la perte ordinale proposée obtient la meilleure précision à 69,7%.

—**Brahim et al [19]** ont proposé une étude afin de faire une détection précoce de l'arthrose du genou, en utilisant une méthode basée sur l'analyse spectrale. Cette méthode, se base sur la densité spectrale de puissance (**DSP**) au-dessus des orientations différentes de l'image comme caractéristique pour la tâche de classification afin de distinguer entre le genou normal (KL grade 0) et l'arthrose minimale (KL grade 2). Ensuite, analyse indépendante des composantes (**ICA**) est utilisée pour sélectionner les cœurs (**DSP**) pertinents pour la détection de l'arthrose. Enfin, un classificateur de régression logistique (**RL**) est utilisé pour classer 688 images radiographiques du genou obtenues à partir de l'Initiative sur l'arthrose (**IAO**). Les résultats de la classification sont à (78,92 %) de précision avec (79,65 %) de sensibilité et (78,20 %) de spécificité.

En conclusions, l'approche de texture qu'ils ont proposée donne de bons résultats de classification et pourrait satisfaire aux contraintes cliniques. Elle peut être hautement efficace en utilisant une grande quantité de données.

—**Rabbia et al [43]** ont présenté une approche hybride sur les caractéristiques du (**CNN**) profond pour détecter l'arthrose du genou. Tout d'abord, ils ont fait des prétraitements sur les images radiographiques d'entrées. Puis, l'extraction des (**ROI**) par segmentation. Ensuite, les caractéristiques sont extraites dans des images radiographiques prétraités contenant la largeur de l'espace articulaire du genou, à l'aide de descripteur de caractéristiques hybrides tels que le (**CNN**) par le biais des motifs binaires locaux (**LBP**), Et le (**CNN**) par le biais de l'histogramme du gradient orienté (**HOG**). Les caractéristiques du bas niveau sont calculées par le (**HOG**), tandis que les caractéristiques des textures sont calculées à l'aide du descripteur (**LBP**). Enfin, des classificateurs multi-classes à savoir (la machine à vecteur de support (**SVM**), Random Forest (**RF**))

et K-Near set Neighbors (**KNN**)) sont utilisées pour la classification de cette maladie, selon le système de Kellgren-Lawrence (KL grades 0 à 4). Une évaluation expérimentale est réalisée sur différentes combinaisons du cadre proposé. Les résultats montrent que le descripteur (**HOG**) fournit une précision de (97%), pour la détection précoce et pour la classification des quatre grades KL.

—**Ganech et Agam [37]** ont essayé de trouver une solution pour la détection précoce de l'arthrose du genou afin de réduire les conséquences de cette pathologie, en utilisant les réseaux de neurones convolutifs (**CNN**) et plus précisément le modèle **ResNet -101**. D'abord, ils ont effectué les prétraitements de données, selon trois processus tels que : la transformée de Fourier circulaire, la fonction linéaire multivariée et l'égalisation d'histogramme pour obtenir des informations plus efficaces sur l'image. Après, les données sont transmises au modèle **ResNet-101** pré entraîné qui a permis d'obtenir une classification meilleure en dépensant moins de temps et d'espace de stockage comparé aux autres méthodes (Foret aléatoire a une précision de (87,45%), Arbre de décision a une précision de (88,90%), **SVM** une précision de (90,05%) et **KNN** avec une précision de (90,97%). Le classificateur **CNN** a atteint une meilleure précision de (94,24%).

### 3.3 Analyse et comparaison

Dans le tableau (3.2) ci-dessous nous effectuerons une étude comparative des approches proposées :

Auteurs	Yassine et al [48] (2016)	Pingjun Chena et al [20] (12 juin 2019)	A. Brahim et al [19] (2019)	Rabbia et al [43](2021)	Agam et Ganech [37] (Avril 2023)
Dataset	Initiative publique multacentrique OsteoArthritis (OAI)	OsteoArthritis Initiative (OAI)	OsteoArthritis Initiative (OAI)	Ensemble de données Knee OsteoArthritis severity grading (les données de Mendeley IV)	OsteoArthritis Initiative (OAI)
Techniques utilisés	-KNN -SMC -LDA - SVM_RBf -DRAE -SAE -AE -ResNet - DenseNet	-YOLOV2 -VGG19	-DSP -ICA -RL	-L'approche hybride avec le descripteur de caractéristiques (HOG)	- CNN (ResNet101)

Résultats (Accuracy)	KNN=78,15% SMC=78,59% LDA=72,69% SVM-RBF=82,53% DRAE=82,53% SAE, AE=80,26% ResNet=59,25% DenseNet=71,67%	Une précision de VGG19 = 69,7%	La précision à 78,92%	Une précision de 97%	Une précision de 94,24%
Avantages	-Le DRAE fonctionne bien dans l'apprentissage des caractéristiques discriminantes. -Le DRAE permet une meilleure classification de l'arthrose du genou.	-YOLOV2 donne des résultats très prometteurs. -Le VGG19 atteint la meilleure performance de classification validant la performance des CNNs.	-La Régression Logistique a une belle interprétation probabiliste. - La DSP extrait au cours des incréments des lignes et des colonnes de chaque ROI qui pourrait être des caractéristiques plus discriminantes pour la détection précoce de l'arthrose.	-L'approche proposée est robuste -Le SVM est l'une des techniques les plus efficaces en termes de mémoire. - Une approche hybride améliore les performances d'un système de détection.	-Les CNN extraient efficacement les caractéristiques. -Les CNN ont contribué à une classification efficace de la maladie. -ResNet101 améliore la vitesse de classification et réduit la complexité du temps de traitement des radiographies.

Inconvenients	-Le DRAE est un réseau binaire qui ne permet que deux classes	-La performance de rappel diminue avec l'utilisation d'un plus grand nombre de boîtes englobantes. -Une faible précision pour les grades 1 et 2	- La DSP une technique de traitement du signal coûteuse en termes de ressources de calculs. - Dans la Régression Logistique l'interprétation des coefficients sont généralement exponentiels ce qui rend leur interprétation plus complexe.	-L'approche proposé est robuste. -Le SVM est l'une des techniques les plus efficaces en termes de mémoire. - Une approche hybride améliore les performances d'un système de détection.	-L'absence des techniques d'optimisation pour affiner le classificateur. -Le processus d'extraction de la région d'intérêt est une tâche ardue.
---------------	---------------------------------------------------------------	----------------------------------------------------------------------------------------------------------------------------------------------------	------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------	----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------	----------------------------------------------------------------------------------------------------------------------------------------------------

TAB. 3.2 : Comparaison des travaux connexes

## 3.4 Conclusion

Dans ce chapitre, nous avons établi un état de l'art sur la prédiction précoce de l'arthrose du genou, qui représente une étude comparative des travaux connexes que nous avons abrégés, nous avons présentés ceci dans un tableau (3.2) détaillé décrivant chaque approche, en suivant chaque travail par un bref paragraphe qui le résume.

Dans le chapitre suivant, nous allons présenter notre approche par rapport à l'analyse des images radiographiques de l'arthrose grade (KL2), les limites de ses images en termes informative, quelques conclusions les concernant et des perspectives.

# Chapitre 4

## Approche proposée



### 4.1 Introduction

Dans nos jours, les systèmes de prédiction précoce de l'arthrose du genou et l'extraction de l'information utile d'une façon automatique sont très importants et aident les médecins à diagnostiquer efficacement les patients arthrosiques.

Le nombre de personnes souffrant de maladie d'arthrose du genou est en augmentation. Un diagnostic précis à un stade précoce suivi d'un traitement ultérieur approprié peut permettre de réduire les risques des complications de cette pathologie.

Dans ce chapitre, nous présenterons en détail notre approche qu'on a utilisé au cours de notre projet ainsi que ses différentes étapes pour la prédiction de la gonarthrose à l'aide de données médicales et des méthodes de traitement automatique.

### 4.2 Contribution

Notre projet consiste à une prédiction précoce de l'arthrose du genou, c'est-à-dire de permettre aux personnes de savoir s'ils ont le risque de développer une arthrose avec un taux de prédiction, et à déterminer si le déterminant textural de la gonarthrose est d'abord visible dans la texture de l'os sous-chondral cortical ou trabéculaire. Pour atteindre cet objectif, nous avons suivi les étapes suivantes : collecte des données, sélection des ROIs, prétraitement, sélection de modèle, entraînement des données, prédiction et calcul de l'Accuracy, évaluations des différents modèles et enfin la sélection de la région la plus informative.

#### 4.2.1 Collecte des données

La collecte des données est une étape initiale très importante pour la prédiction de la gonarthrose. Cela permet de traiter et évaluer l'approche choisie. Le dataset d'arthrose du genou est un ensemble de données initiatrice, extrait dans la base publique multicentrique OsteoArthritis initiative (OAI), il se compose de plusieurs images (radiographiques « Rayon X » et résonance magnétique « IRM ») prédictives médicales.

#### 4.2.2 Sélection des ROI

Pour déterminer la progression radiographique de l'arthrose du genou, une association forte entre la texture de l'os sous-chondral et la sévérité de l'arthrose est nécessaire. Par conséquent, la localisation des ROI est une étape cruciale pour l'analyse de la texture. Dans cette étude nous avons faites la sélection automatiquement, et a été effectués par plusieurs étapes :

- Séparation automatique des genoux et du fémur et tibia (Figure 4.1).




FIG. 4.1 : A. séparation automatique des genoux B. séparation automatique du fémur et tibia [58]

- Localisation du plateau tibiale (Figure 4.2).

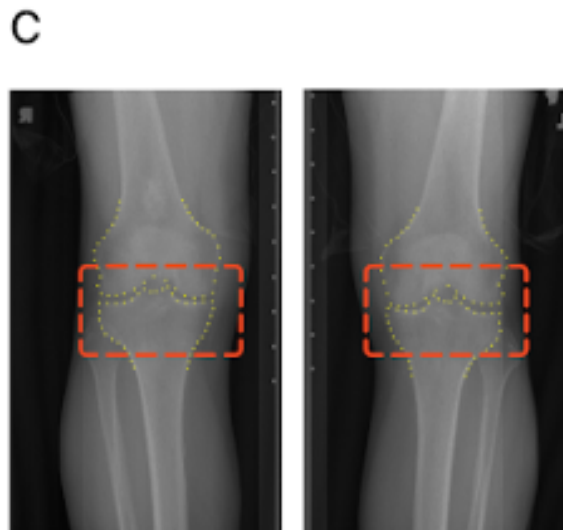


FIG. 4.2 : Détection du plateau tibiale [58]

- **Sélection des ROI** : Nous avons extrait 4 contours par homothétie de rapport  $K$ , sur les 37 points de chaque contour, nous avons sélectionné 7 points spécifiques (9, 11, 15, 19, 23, 27 et 29) comme centre de chaque ROI sélectionné. Par conséquent, 7 ROI ( $\mathbf{R}$ ) ont été extraites de chaque contour secondaire ce qui donne un total de ( $4 \times 7 = 28$  ROIs) extraites de chaque image avec une taille ( $16 \times 16$ ) (Figure 4.3) [59].

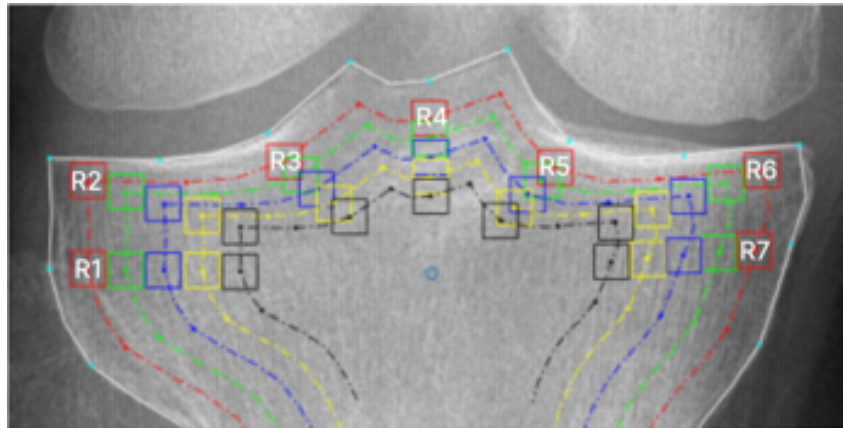


FIG. 4.3 : Sélection des ROI [58]

Les contours extraits dans la (Figure 4.3) au dessus sont :

- Contour1 (en rouge).
- Contour2 (en vert).
- Contour3 (en bleu).
- Contour4 (en jaune).

### 4.2.3 Prétraitement

Les prétraitements effectués sur l'ensemble de dataset sont :

- Redimensionnement des images.
- Normalisation des images : la moyenne égale à 0 et l'écart type égale à 1.

### 4.2.4 Répartition des données

La répartition des données consiste à diviser notre dataset en trois parties :

- **Données d'entraînement** : sur lesquels nous pourrions entraîner nos modèles.
- **Données de validation** : sur lesquels nous évaluerons les différents modèles, afin de sélectionner un modèle définitif et de trouver les meilleurs hyper paramètres (Lr, Regularisateur Wd, Batch size, ...etc.).
- **Données de test** : sur lesquelles nous utiliserons pour tester la précision du modèle final (ajusté). Il est important que les données de test ne soient même pas consultées pendant le processus d'entraînement et d'ajustement des paramètres et de sélection du modèle afin d'éviter un surapprentissage et d'avoir une précision précise [22].

### 4.2.5 Sélection du modèle

Après la répartition des données, l'étape suivante est la sélection du modèle pour la prédiction de l'arthrose du genou. La sélection du modèle consiste à entraîner différents

modèles avec différents choix d'hyper paramètres sur l'ensemble des données d'entraînement, afin de choisir le meilleur modèle. Cependant, l'évaluation réelle de ces algorithmes pour sélectionner le meilleur modèle n'est pas effectuée sur les données d'apprentissage, mais sur un ensemble de données de validation distinct afin d'éviter de favoriser les modèles surajoutés [22].

La partie la plus difficile dans la sélection du modèle est le réglage ou le choix d'hyper paramètres du modèle. Ci-dessous les différents modèles des réseaux de neurones convolutifs (**CNN**) et plusieurs réglages d'hyper paramètres qu'on a utilisées afin de les comparés et de sélectionnée le meilleur classifieur pour classifier l'arthrose du genou (sain ou malade) et de déterminer si le déterminant textural de la gonarthrose est d'abord visible dans la texture de l'os sous-chondral cortical ou trabéculaire :

### —Les modèles utilisés

- VGG16
- VGG19
- InceptionV3
- ResNet152V2

### —Le réglage des hyperparamètres

Est considérés comme l'étape la plus difficile et la plus importante dans le Deep Learning. Les différents paramètres qu'on a réglés et choisis sont :

- **Optimiseur**  
Nous avons utilisé l'optimiseur d'Adam.
- **Taux d'apprentissage  $\alpha$**   
Contrôle la taille des pas que prend l'algorithme d'optimisation pour converger vers un minimum local de la fonction de perte, on a essayé plusieurs taux  $\alpha$  pour chaque modèle :  $(10^2, 10^3, 10^4, 10^5, 10^6, 10^7)$ .
- **Weight decay ou Regularisateur L2**  
Fonctionne en ajoutant un terme de pénalité à la fonction de perte du modèle afin d'évité le surapprentissage « Overfitting » et rendre le modèle plus stable.  
 $\lambda$  : est un hyperparamètre appelé coefficient de régularisation ou lambda.  
On a essayé quelques coefficients pour chaque modèle :  $(0,01; 0,001; 0,0001; 0,5; 0.005; 0.9; 1)$ .
- **Loss**  
Est une mesure qui évalue la différence entre les prédictions d'un modèle et les valeurs réelles, on a utilisé Binary cross-entropie car on fait une classification binaire.

- **Metrique**

On a utilisé (Binary Accuracy, Threshold=0.5) car elle calcule le taux de correspondance entre les prédictions et les étiquettes binaires et elle répond à notre problème, voici une démonstration de son fonctionnement (Figure 4.4) :

```
>>> m = tf.keras.metrics.BinaryAccuracy()
>>> m.update_state([[1], [1], [0], [0]], [[0.98], [1], [0], [0.6]])
>>> m.result().numpy()
0.75
```

FIG. 4.4 : Binary\_accuracy [46]

- **Batch\_size**

La taille du batch (batch size) fait référence au nombre d'échantillons d'entraînements utilisés dans une itération d'apprentissage lors de la mise à jour des poids d'un modèle d'apprentissage automatique. On a essayé trois différentes tailles : (32, 64, 128, 256) et on a opté pour 64 pour ne pas saturer la RAM.

- **Shuffle**

La fonction Shuffle « mélanger » fait référence à une opération qui consiste à réorganiser aléatoirement l'ordre des échantillons dans un ensemble de données. Cela est souvent utilisé lors de la préparation des données pour l'entraînement d'un modèle d'apprentissage automatique. L'opération de mélange des données est réalisée dans le but d'éviter tout biais lié à l'ordre d'apparition des échantillons lors de l'entraînement. Shuffle est une variable booléenne a vrai ou faux, et on a optés pour Vrai i.e. mélanger les échantillons dans un ensemble de données.

- **Taux de validation**

On a essayé 10% et 20% et finalement on a opté pour 20%.

- **Layer trainable**

Les couches trainable sont celles dont les poids sont modifiés pendant l'entraînement. Premièrement, on a gelé les couches entraînées et on a rajoutés les couches de sorties, après on les a entraînées.

- **Utilisation d'early stoping et check point**

L'utilisation conjointe de l'Early Stopping et des checkpoints permet de garantir à la fois la meilleure performance du modèle et une sauvegarde régulière de ses progrès. L'Early Stopping permet d'arrêter l'entraînement lorsque les performances stagnent, évitant ainsi le surapprentissage. Les checkpoints assurent que les meilleurs paramètres du modèle sont sauvegardés de manière régulière, ce qui permet de reprendre l'entraînement à partir du dernier point de sauvegarde en cas de besoin.

## 4.3 Conclusion

Dans ce chapitre, nous avons présenté en détail notre approche de prédiction de l'arthrose du genou, en utilisant les modèles des réseaux de neurones convolutifs (CNN), et

plusieurs réglages d'hyper paramètres pour sélectionner un meilleur modèle qui fait une bonne classification.

Dans le chapitre suivant nous procéderons à l'explication de tous les aspects liés à l'implémentation de notre approche.

# Chapitre 5

## Réalisation

### 5.1 Introduction

Ce chapitre se concentre sur l'implémentation de la méthode de prédiction de l'arthrose du genou. Nous avons développé un système basé sur les CNN pour détecter et prédire précocement l'arthrose du genou. Nous détaillerons les étapes suivies pour mettre en place notre modèle de prédiction et les choix que nous avons faits en termes d'hyper paramètres du modèles, de techniques de prétraitement des données et d'évaluation des performances.

L'objectif principal de cette implémentation est de traduire les concepts théoriques et les approches méthodologiques discutés dans les chapitres précédents en une application concrète. Nous présenterons également les outils et les technologies utilisés pour la mise en œuvre de notre méthode. Cela comprendra les langages de programmation, les bibliothèques logicielles, les environnements de développement et les ressources matérielles nécessaires pour mener à bien cette tâche.

Enfin, nous discuterons des résultats obtenus à partir de notre implémentation et de leur pertinence par rapport à notre objectif de prédiction de l'arthrose du genou. Nous évaluerons les performances du modèle et analyserons les résultats de précision.

### 5.2 Expérimentation

#### 5.2.1 Dataset

Les images radiographiques du genou utilisées dans la prédiction précoce de la gonarthrose ont été obtenues à partir de la base de données publique appelée OsteoArthritis Initiative (OAI), accessible au grand public à l'adresse « <http://www.oai.ucsf.edu/> ». L'OAI est une étude prospective, longitudinale et multicentrique portant sur l'arthrose du genou. La base de données OAI comprend des radiographies bilatérales du genou, prises en position de flexion fixe, provenant de 4796 hommes et femmes suivis depuis 2008. Les participants ont entre 45 et 79 ans.

Cette étude se concentre sur la détection précoce de l'arthrose du genou (KL2), qui est particulièrement difficile. Par conséquent, seules les radiographies numériques (modalité CR) ont été prises en considération, avec un grade KL = 0 (considérées comme sujet sain) et KL = 2 (considéré comme sujet arthrosique) ont été utilisés. Ainsi, un total de 4108 radiographies du genou a été utilisé, 2421 (sujet sain) et 1687 (sujet arthrosique).

Ensuite, une extraction de 28 ROI est faites pour chaque image par une segmentation automatique [58]. Le Dataset est divisé en deux parties :



### —Dataset d’entraînement

Le Dataset d’entraînement constitue la base sur laquelle le modèle doit être entraîné afin de généraliser la solution et classifier les sujets sains (KL0) ou arthrosiques (KL2). Les caractéristiques de chaque image sont les suivantes :

- La dimension initiale ( $16 \times 16 \times 1$ ) .
- Redimensionnement des images ( $150 \times 150 \times 3$ ).
- Chaque pixel est représenté par une valeur numérique entre  $[0,255]$ , dupliqué sur trois canaux.
- **Division de ce Dataset en deux** : 80% données d’entraînement et 20% données de validation.

### —Dataset de test

Le Dataset de test est la base sur laquelle nous évaluerons enfin l’erreur de généralisation du modèle. Ce Dataset contient 100 images appartenant à 2 classes (KL0 et KL2) elles respectent la même définition et le même format que les images du Dataset d’entraînement.

## 5.2.2 Environnement de développement

### —Google colabatory (Colabs)

Est une plateforme en ligne qui permet d’écrire un code, un texte et l’exécution du code Python et l’affichage des résultats sur des pages web interactives. Son environnement incluent :

- Un espace de stockage temporaire de taille  $\geq 70$  gigaoctet.
- Différents processeurs de type CPU, GPU, TPU « on a utilisé la GPU ».
- Une RAM de taille  $\geq 12$  gigaoctet.

## 5.2.3 Langage de programmation

### —Python

Python est un langage de programmation à la fois puissant et facile à apprendre. Il offre des structures de données de haut niveau qui sont efficaces, ainsi qu’une approche simple mais efficace pour la programmation orientée objet. La syntaxe élégante et le typage dynamique de Python, combinés à sa nature interprétée, font un langage idéal pour écrire des scripts et développer rapidement des applications dans de nombreux domaines et sur la plupart des plates-formes [55].

### 5.2.4 Bibliothèques de Python

Parmi les bibliothèques utilisés nous avons :

#### —Numpy

Numpy « Numérique Python » est une bibliothèque polyvalente de traitement de tableaux. Elle propose des objets de tableaux multidimensionnels performants et des outils pour manipuler ces tableaux, elle facilite les opérations mathématiques et leur vectorisation . Cela se traduit par des performances améliorées et une accélération significative du temps d'exécution [45].

#### —Matplotlib

Matplotlib est une bibliothèque complète permettant de créer des visualisations statiques, animées et interactives en Python [44]. Dans notre étude, Matplotlib nous a permis de tracer les courbes d'apprentissage et de la fonction Loss pour visualiser l'avancement de notre modèles [45].

#### —Tensorflow/ Keras

- **Tensorflow** Est une bibliothèque d'intelligence artificielle qui aide les développeurs à créer des réseaux de neurones à grande échelle avec de nombreuses couches en utilisant des graphiques de flux de données. Tensorflow facilite également la création de modèles Deep Learning. Il est utilisé par Google, Coca-Cola, Twitter, Intel et autres.

On retrouve cette bibliothèque également en reconnaissance faciale voix et son, analyse de sentiments, Google Translate, Recommandation d'Amazon, de Google et de Netflix et beaucoup d'autres domaines d'application de l'IA [45].

- **Keras**

Keras est une bibliothèque open-source dédiée au deep learning. Elle est de niveau plus élevé que tensorflow ce qui permet de simplifier encore plus la mise en œuvre de réseaux plus complexes. Avec Keras le travail avec les images est beaucoup plus facile. Dans notre cadre d'étude Keras nous a permis de :

- Déterminer le pourcentage de précision.
- Définir la fonction de perte.
- Créer des couches de fonctions personnalisées.
- Traitement intégré des données et des images[45].

## 5.3 Les Résultats du travail précédent

Des travaux précédents ont été menés dans le cadre de la prédiction précoce de l'arthrose du genou, par une équipe de Laboratoire Limed sur le Ddataset OstéoArthritis initiative (OAI) [58].

### 5.3.1 La méthode

—Utilisation de Bon Finder pour l'extraction automatique des patches :

- Patches os sous-chondral cortical.
- Patches os sous-chondral trabéculaire.
- Différentes tailles (16x16, 32x32, etc.).
- Déplacement par pas d'environ 5 pixels au moins.

—Utilisation d'un CNN avec 2 couches, sur les patches montrés sur la (Figure 5.1) ci-dessous.




FIG. 5.1 : **A.** Patches des contours (tibia + fémur), **B.** Patches du contour extérieur du tibia et **C.** Patches du contour intérieur du tibia [59]

### 5.3.2 Les résultats

Les résultats obtenus par l'analyse de ces patches par le réseau CNN avec deux couches est de (64.77%) de précision sur les données de validation (Figure 5.2).




FIG. 5.2 : Les résultats de précision sur les différentes tailles des ROIs [59]

## 5.4 L'approche proposée

Pour améliorer les résultats du travail précédent qui consiste à déterminer si le déterminant textural de la gonarthrose est d'abord visible dans la texture de l'os sous-chondral cortical ou dans celle de l'os sous-chondral trabéculaire, nous avons proposé une approche qui s'inscrit dans la même optique en utilisant les réseaux de neurones convolutifs (CNNs) pré entraînés :

### 5.4.1 La première étape

Cette première étape consiste à sélectionner le meilleur modèle. On a appliqué quatre différents modèles (VGG16, VGG19, ResNet152V2 et InceptionV3) sur quatre contours concaténés, chaque contour contient 7 régions (Figure 5.3).




FIG. 5.3 : Quatre contours concaténés

Les paramètres utilisés dans cette méthode sont :

- Taille d'image :  $(150 \times 150 \times 3)$ .
- Data d'entraînement : 80%.
- Data de validation : 20%.
- Nombre d'epochs : 300
- Batch\_size : 256.

La taille des paramètres des modèles utilisées :

- **VGG16** : 16812353.
- **VGG19** : 22122049.
- **ResNet152V2** : 71439361
- **InceptionV3** : 26521889.

Les mots clés des tableaux de résultats ci-dessous :

- **Lr** : Learning rate.
- **Régulariser L2 ou Weight Decay** : Wd.
- **Train\_accuracy** : les résultats d'entraînement.
- **Val\_accuracy** : les résultats de validation.

Modèles	VGG16	VGG19	ResNet152V2	InceptionV3
<b>Lr</b>	$10^{-3}$	$10^{-3}$	$10^{-3}$	$10^{-4}$
<b>Wd</b>	1	1	1	1
<b>Train_accuracy</b>	62%	64%	64%	63%
<b>Val_accuracy</b>	70%	73%	69%	69%

TAB. 5.1 : Les résultats de la première méthode

### —Entraînement

#### VGG16

```
Epoch 36: val_binary_accuracy improved from 0.70226 to 0.70908, saving model to /content/drive/My Drive/hp_2_64_1_300_vgg16_test_.hdf5  
50/50 - 9s - loss: 0.7953 - binary_accuracy: 0.6253 - val_loss: 0.7383 - val_binary_accuracy: 0.7098 - 9s/epoch - 182ms/step  
Epoch 37/300
```

#### VGG19

```
Epoch 190: val_binary_accuracy improved from 0.72613 to 0.73241, saving model to /content/drive/My Drive/hp_3_64_1_300_vgg19_test_.hdf5  
50/50 - 11s - loss: 0.6907 - binary_accuracy: 0.6438 - val_loss: 0.6287 - val_binary_accuracy: 0.7324 - 11s/epoch - 215ms/step  
Epoch 191/300
```

#### ResNet152V2

```
Epoch 45: val_binary_accuracy improved from 0.68719 to 0.69221, saving model to /content/drive/My Drive/hp_3_256_1_300_resnet152v2_test_.hdf5  
13/13 - 19s - loss: 0.6783 - binary_accuracy: 0.6423 - val_loss: 0.6520 - val_binary_accuracy: 0.6922 - 19s/epoch - 1s/step  
Epoch 46/300
```

#### InceptionV3

```
Epoch 155: val_binary_accuracy improved from 0.68342 to 0.69221, saving model to /content/drive/My Drive/hp_4_64_1_300_inceptionv3_test_.hdf5  
50/50 - 5s - loss: 0.6680 - binary_accuracy: 0.6319 - val_loss: 0.6642 - val_binary_accuracy: 0.6922 - 5s/epoch - 92ms/step  
Epoch 156/300
```

FIG. 5.4 : L'entraînement de différents modèles

### —Visualisation des résultats

#### VGG16




FIG. 5.5 : Les résultats du VGG16

### VGG19




FIG. 5.6 : Les résultats du VGG19

### ResNet152V2




FIG. 5.7 : Les résultats du ResNet152V2

## InceptionV3




FIG. 5.8 : Les résultats de l’InceptionV3

### —Analyse de la méthode

Selon le tableau (5.1), la meilleur précision a été obtenue en utilisant le classifieur VGG19 avec une précision de (73%) par rapport à VGG16 (70%), ResNet152V2 et InceptionV3 (69%). Ces résultats montrent que le classifieur VGG19 donne en générale de meilleure performance, ce qui nous a conduit à l’appliquer dans la prochaine étape afin de déterminer la région la plus informative.

### 5.4.2 La deuxième étape

Dans cette étape, on a appliqués le modèle VGG19 sur chacun des quatre contours afin de sélectionner le meilleur parmi ses derniers. Les paramètres utilisés dans cette méthode sont :

- Taille d’image : (150 × 150 × 3).
- Data d’entraînement : 80%.
- Data de validation : 20%.
- Nombre d’epochs : 100.
- Batch\_size : 256.



Contours	C1	C2	C3	C4
Lr	10 <sup>-3</sup>	10 <sup>-3</sup>	10 <sup>-3</sup>	10 <sup>-3</sup>
Wd	0.9	0.9	0.9	0.9
Train_accuracy	62%	58%	61%	58%
Val_accuracy	70%	67%	68%	66%

TAB. 5.2 : Les résultats de la deuxième étape en appliquant le VGG19

—Entraînement

**C1**

```
Epoch 45: val_binary_accuracy improved from 0.69849 to 0.78352, saving model to /content/drive/My Drive/hp_3_256_0.9_100_vgg19_test_.hdf5
13/13 - 11s - loss: 0.6800 - binary_accuracy: 0.6228 - val_loss: 0.6382 - val_binary_accuracy: 0.7835 - 11s/epoch - 870ms/step
Epoch 46/100
```

**C2**

```
Epoch 10: val_binary_accuracy improved from 0.66583 to 0.67839, saving model to /content/drive/My Drive/hp_3_256_0.9_100_C2_vgg19_test_.hdf5
13/13 - 11s - loss: 1.4559 - binary_accuracy: 0.5850 - val_loss: 1.3079 - val_binary_accuracy: 0.6784 - 11s/epoch - 848ms/step
Epoch 11/100
```

**C3**

```
Epoch 44: val_binary_accuracy improved from 0.67714 to 0.68467, saving model to /content/drive/My Drive/hp_3_256_0.9_100_C3_vgg19_test_.hdf5
13/13 - 11s - loss: 0.6822 - binary_accuracy: 0.6165 - val_loss: 0.6585 - val_binary_accuracy: 0.6847 - 11s/epoch - 811ms/step
Epoch 45/100
```

**C4**

```
Epoch 14: val_binary_accuracy improved from 0.66332 to 0.66457, saving model to /content/drive/My Drive/hp_3_256_0.9_100_C4_vgg19_test_.hdf5
13/13 - 11s - loss: 0.9786 - binary_accuracy: 0.5888 - val_loss: 0.8962 - val_binary_accuracy: 0.6646 - 11s/epoch - 834ms/step
Epoch 15/100
```

FIG. 5.9 : L'entraînement de VGG19 sur les quatre contours

—Visualisation des résultats

Contour1




FIG. 5.10 : Les résultats de VGG19 sur le C1

Contour2




FIG. 5.11 : Les résultats de VGG19 sur le C2

### Contour3




FIG. 5.12 : Les résultats de VGG19 sur le C3

### Contour4




FIG. 5.13 : Les résultats de VGG19 sur le C4

#### —Analyse de la méthode

Les résultats présentés dans le tableau (5.2) prouvent que le C1 est le plus informatif avec une précision de (70%), comparé à C2 (67%), C3 (68%) et C4 (66%). On choisit le C1 pour appliquer la dernière étape sur les 7 ROIs de ce contour.

### 5.4.3 La troisième étape

Dans cette dernière étape, on a appliqué le modèle VGG19 sur chacune des sept régions du premier contour afin de déterminer la région la plus informative.

Les paramètres utilisés dans cette méthode sont :

- Taille d'image : (150 × 150 x 3).
- Data d'entraînement : 80%.
- Data de validation : 20%.
- Nombre d'epochs : 100.
- Batch\_size : 256.

Régions	R1	R2	R3	R4	R5	R6	R7
<b>Lr</b>	$10^{-3}$	$10^{-3}$	$10^{-3}$	$10^{-3}$	$10^{-3}$	$10^{-3}$	$10^{-3}$
<b>Wd</b>	0.9	0.9	0.9	0.9	0.9	0.9	0.9
<b>Train_accuracy</b>	58%	57%	72%	54%	68%	68%	57%
<b>Val_accuracy</b>	66%	66%	68%	66%	67%	67%	66%

TAB. 5.3 : Les résultats de la troisième étape en appliquant le VGG19

#### —Entraînement

##### R1

```
Epoch 5: val_binary_accuracy improved from 0.63065 to 0.66206, saving model to /content/drive/My Drive/hp_3_256_0.9_100_C1R1_vgg19_test_.hdf5
13/13 - 11s - loss: 2.0659 - binary_accuracy: 0.5894 - val_loss: 1.5052 - val_binary_accuracy: 0.6621 - 11s/epoch - 842ms/step
Epoch 6/100
```

##### R2

```
Epoch 53: val_binary_accuracy improved from 0.66206 to 0.66457, saving model to /content/drive/My Drive/hp_3_256_0.9_100_C1R2_vgg19_test_.hdf5
13/13 - 12s - loss: 0.7559 - binary_accuracy: 0.5743 - val_loss: 0.7170 - val_binary_accuracy: 0.6646 - 12s/epoch - 889ms/step
Epoch 54/100
```

##### R3

```
Epoch 45: val_binary_accuracy improved from 0.68216 to 0.68342, saving model to /content/drive/My Drive/hp_3_256_0.9_100_C1R3_vgg19_test_.hdf5
13/13 - 11s - loss: 0.6236 - binary_accuracy: 0.7221 - val_loss: 0.6881 - val_binary_accuracy: 0.6834 - 11s/epoch - 816ms/step
Epoch 46/100
```

FIG. 5.14 : L'entraînement de VGG19 sur les régions 1, 2, 3

R4

```
Epoch 6: val_binary_accuracy improved from 0.64196 to 0.66206, saving model to /content/drive/My Drive/hp_3_256_0.9_100_C1R4_vgg19_test_.hdf5  
13/13 - 11s - loss: 1.4763 - binary_accuracy: 0.5979 - val_loss: 1.2291 - val_binary_accuracy: 0.6621 - 11s/epoch - 829ms/step  
Epoch 7/100
```

R5

```
Epoch 2: val_binary_accuracy improved from 0.54020 to 0.66206, saving model to /content/drive/My Drive/hp_3_256_0.9_100_C1R5_vgg19_test_.hdf5  
13/13 - 10s - loss: 44.9982 - binary_accuracy: 0.5489 - val_loss: 15.6155 - val_binary_accuracy: 0.6621 - 10s/epoch - 731ms/step  
Epoch 3/100
```

FIG. 5.15 : L'entraînement de VGG19 sur les régions 4, 5

R6

```
Epoch 45: val_binary_accuracy improved from 0.67337 to 0.67714, saving model to /content/drive/My Drive/hp_3_256_0.9_100_C1R6_vgg19_test_.hdf5  
13/13 - 11s - loss: 0.6677 - binary_accuracy: 0.6888 - val_loss: 0.6998 - val_binary_accuracy: 0.6771 - 11s/epoch - 810ms/step  
Epoch 46/100
```

R7

```
Epoch 8: val_binary_accuracy improved from 0.66000 to 0.66583, saving model to /content/drive/My Drive/hp_3_256_0.9_100_C1R7_vgg19_test_.hdf5  
13/13 - 10s - loss: 1.0291 - binary_accuracy: 0.5775 - val_loss: 0.9424 - val_binary_accuracy: 0.6658 - 10s/epoch - 799ms/step  
Epoch 9/100
```

FIG. 5.16 : L'entraînement de VGG19 sur les régions 6, 7

—Visualisation des résultats

Région1




FIG. 5.17 : Les résultats de VGG19 sur la R1

Région2




FIG. 5.18 : Les résultats de VGG19 sur la R2

Région3




FIG. 5.19 : Les résultats de VGG19 sur la R3

Région4




FIG. 5.20 : Les résultats de VGG19 sur la R4

Région5




FIG. 5.21 : Les résultats de VGG19 sur la R5

Région6




FIG. 5.22 : Les résultats de VGG19 sur la R6

### Région7




FIG. 5.23 : Les résultats de VGG19 sur la R7

### —Analyse de la méthode

Comme on peut le constater, les résultats dans le tableau (5.3) montrent que la région la plus distinctive est la région 3, située dans la partie médiale dans le tibia (Figure 5-16), avec une précision de (68%), par rapport au R5 et R6 (67%), la R1, R2, R4 et R7 (66%).

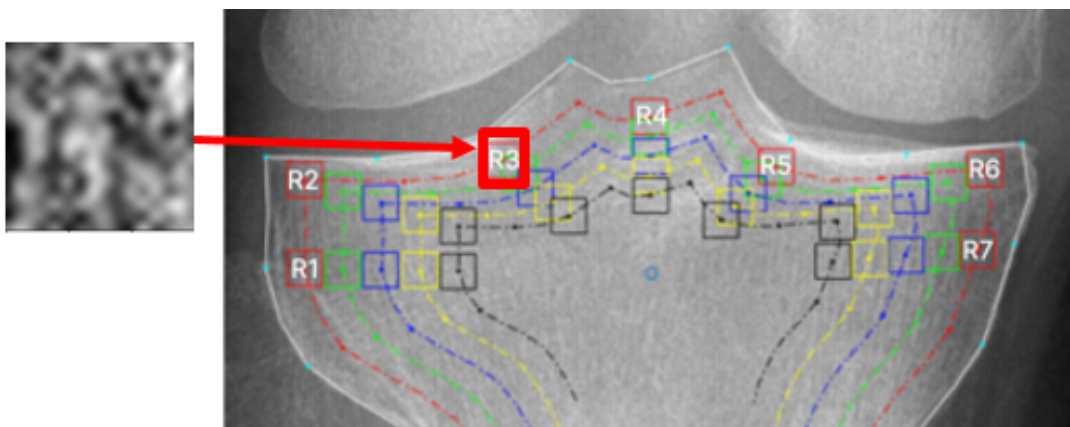


FIG. 5.24 : La région 3 la plus informative



### 5.5 Conclusion

Nous avons présenté dans ce chapitre les modèles des CNN et nous avons sélectionnées le plus performant VGG19 avec une précision de 73%. Les résultats de classification des ROIs à des cas arthrosique précoce « KL2 » du genou et a des sujets sains, montrent que les classes sont très similaires, ce qui rend la tâche de classification plus difficile. Les résultats obtenus montrent que la région la plus discriminante était située dans le compartiment médial du genou, ce qui a également été démontré dans l'étude [48]. Par conséquent, les résultats de précision obtenus dans cette étude est très faible et cela est dû au contenu informatif limité des radiographies utilisées qui nécessitent un éventuel prétraitement avec des méthodes de traitement avancé d'images.

# Conclusion générale

Ce travail a été réalisé dans le cadre de notre projet de fin de cycle Master en informatique option intelligence artificielle. Il a consisté en application du Deep Learning pour la prédiction précoce de la maladie d'arthrose du genou (gonarthrose). La prédiction de la gonarthrose est un sujet très étudié par les chercheurs dans le but de réaliser des systèmes automatiques prédictifs qui permettent aux médecins de minimiser les risques de complication provenant de l'arthrose. L'analyse prédictive dans le domaine de la santé peut changer la façon avec laquelle les chercheurs et les praticiens obtiennent des informations à partir de données médicales et prendre des bonnes décisions au moment opportun.

Le Deep Learning est la technique la plus utilisée actuellement pour la prédiction et la classification des images radiographiques. Et nous savons que des modèles pré-entraînés sur imagesNet peuvent donner des résultats très satisfaisant dans la classification des images (transfert Learning). Ce qui nous a amené à tenter cette technique pour la prédiction précoce (niveau KL2) de la gonarthrose par classification. Et dans notre travail, nous avons utilisé les modèles de réseaux de neurones convolutifs (CNN) tels que « VGG16, VGG19, ResNet152V2 et InceptionV3 » connus pour être les plus performants dans la classification. Néanmoins, trouver les hyper paramètres adéquats s'avère la tâche la plus difficile à faire dans la technique du Deep Learning. Les résultats obtenus, dans l'étape une de notre travail, sur les radiographies de l'arthrose, par les différents modèles nous mènent à choisir le VGG19 (73%) pour affiner notre étude qui consiste à trouver, au final, la région la plus riche en terme de caractéristiques discriminatives de la maladie d'arthrose. Le fait que le VGG19 donne le meilleur score nous renseigne que les sauts de connexion de ResNet et l'extraction de caractéristiques à différentes échelles de Inception n'ont pu rien apporter pour une meilleure classification.

Les tests expérimentaux ont été menés sur la base de données « OAI ». Dans chaque radiographie 28 régions représentant la microstructure de l'os sou-chondral trabéculaire et cortical ont été utilisées et les résultats obtenus montrent que la région la plus informative est celle située dans le compartiment médial du genou (région 3 du contour 1). Une raison plausible est que l'arthrose du genou se produit dans cette région à cause de la charge biomécanique importante sur cette partie du genou.

Les résultats de classification des ROI montrent qu'elles pourraient fournir des informations plus au moins discriminatives sur le changement de la microstructure osseuse dû à l'arthrose et jouent un rôle important dans la prédiction précoce de la gonarthrose. Cependant, il convient de noter que notre travail présente certaines limites, et cela est du

(il s'est révélé) à l'utilisation d'images radiographiques limitées en caractéristiques discriminatives qui induit en erreurs les différents réseaux entraînés. Ce que justifie les valeurs de probabilités de classification à la sortie des réseaux qui tourne autour de 0.5 et dont peu d'images ont été classifiées de façon consistante (probabilité qui tendent vers 1 pour les cas arthrosiques et vers 0 pour les cas sains). Donc Un prétraitement d'image avec des méthodes pertinentes est plus que nécessaire pour améliorer davantage les performances prédictives.

Notre travail peut modestement contribuer à l'avancement des connaissances dans le domaine de la prédiction précoce de la gonarthrose en utilisant les CNN. Nos résultats ouvrent la voie à de futures recherches visant à améliorer encore les performances du modèle et à relever les défis. Soit en se concentrant plus sur la région 3 soit en appliquant un pré traitement aux images d'entrée, ce que nous prévoyons comme perspectives.

Les perspectives découlant de nos travaux sont nombreuses, les plus importantes sont les suivantes :

- se focaliser sur la région 3 du contour 1 en augmentant ou en réduisant sa taille.
- Effectuer des prétraitements avec des méthodes pertinentes sur les radiographies X.
- Utiliser d'autres types d'imageries médicales et comparer les résultats.
- Explorer d'autres paradigmes de Deep Learning (Auto encodeur, ..) afin d'avoir une meilleure compréhension et distinction des informations (caractéristiques).

# Bibliographie

- [2] Ferket et al. et AL. In : (2017).
- [3] O’Neill et AL. “Les statistique de l’arthrose”. In : (2018).
- [4] Mme Françoise ALLIOT-LAUNOIS. “Préambule Sommaire”. In : ().
- [8] Joseph ANTONY et al. “Quantifying radiographic knee osteoarthritis severity using deep convolutional neural networks”. In : *2016 23rd International Conference on Pattern Recognition (ICPR)*. IEEE. 2016, p. 1195-1200.
- [19] Abdelbasset BRAHIM, Rabia RIAD et Rachid JENNANE. “Knee osteoarthritis detection using power spectral density : Data from the osteoarthritis initiative”. In : *Computer Analysis of Images and Patterns : 18th International Conference, CAIP 2019, Salerno, Italy, September 3–5, 2019, Proceedings, Part II 18*. Springer. 2019, p. 480-487.
- [20] Pingjun CHEN et al. “Fully automatic knee osteoarthritis severity grading using deep neural networks with a novel ordinal loss”. In : *Computerized Medical Imaging and Graphics 75* (2019), p. 84-92.
- [30] Theodoros DIMITROULAS et al. “Neuropathic pain in osteoarthritis : a review of pathophysiological mechanisms and implications for treatment”. In : *Seminars in arthritis and rheumatism*. T. 44. 2. Elsevier. 2014, p. 145-154.
- [34] Thomas JANVIER. “Caractérisation de la gonarthrose sur radiographie X par analyse de la texture de l’os trabéculaire”. Thèse de doct. Université d’Orléans, 2016.
- [35] Halima Essaadiya KATHOUTH, Chaima REGGAB et al. “Etude Comparative Des Différentes Types Des RNA Utilisés Pour La Prévisions De La Vitesse Du Vent”. Thèse de doct. university of M’sila, 2021.
- [36] Mark D KOHN, Adam A SASSOON et Navin D FERNANDO. “Classifications in brief : Kellgren-Lawrence classification of osteoarthritis”. In : *Clinical Orthopaedics and Related Research® 474* (2016), p. 1886-1893.
- [37] Agam. KUMAR M Ganesh Goswami. “Deep Convolutional Neural Network Classifier for Effective Knee Osteoarthritis Classification”. In : *International Journal on Recent and Innovation Trends in Computing and Communication* (2023).
- [42] MOUAFO MOUNGANG Sylvie LUCRÈCE et NZEUSSEU T ADRIEN. “La gonarthrose : ses répercussions dans la vie quotidienne de ceux qui en souffrent et accompagnement thérapeutique”. In : *La gonarthrose 46* ().
- [43] Rabbia MAHUM et al. “A novel hybrid approach based on deep cnn features to detect knee osteoarthritis”. In : *Sensors 21.18* (2021), p. 6189.

- [45] Kamel MESBAHI et al. “Un modèle d’apprentissage automatique pour la prédiction des maladies, cas d’étude : cancer du sein”. Thèse de doct. Université Mouloud Mammeri, 2020.
- [48] Yassine NASSER et al. “DIAGNOSTIC DE L’OSTÉOPOROSE EN UTILISANT L’AUTO-ENCODEUR PROFOND AVEC SVM”. In : ().
- [52] Youssef OUAKRIM. “Classification de sujets asymptomatiques et gonarthrosiques en fonction des données cinématiques comparaison de l’approche globale et de l’approche locale”. Thèse de doct. École de technologie supérieure, 2011.
- [53] Sushant PATRIKAR. “Batch, Mini Batch and Stochastic Gradient Descent. 2019”. In : *URL : <https://towardsdatascience.com/batch-mini-batch-stochastic-gradientdescent-7a62ecba642a>* (2021).
- [59] Mahedi TINHINANE. “Dataset OAI”. In : (2022-2023).

# Webographie

- [1] LASKRI Samia AIBOUD LILA. *Généralité sur l'apprentissage automatique*. en. 2020. URL : <https://www.ummtto.dz/dspace/bitstream/handle/ummtto/13162/Aiboud%5C%20L%5C%3B%5C%20Laskri%5C%20S..pdf?sequence=1&isAllowed=y> (visité le 30/03/2023).
- [5] *Anatomie du genou*. en. URL : <https://www.ccor17.fr/anatomie-genou.php> (visité le 29/03/2023).
- [6] *Anatomie du genou*. en. URL : <https://www.ccor17.fr/anatomie-genou.php> (visité le 29/03/2023).
- [7] *Anomalie*. en. URL : <https://public.larhumatologie.fr/grandes-maladies/arthrose/quelles-sont-les-causes-de-larthrose> (visité le 28/03/2023).
- [9] *Architecture d'un Cnn*. en. URL : <https://datascientest.com/convolutional-neural-network> (visité le 16/05/2023).
- [10] *Arnaud Deltour\_ Gonarthrose.pdf*. en. URL : [https://oer.uclouvain.be/jspui/bitstream/20.500.12279/222/1/Arnaud%5C%20Deltour\\_Gonarthrose.pdf](https://oer.uclouvain.be/jspui/bitstream/20.500.12279/222/1/Arnaud%5C%20Deltour_Gonarthrose.pdf) (visité le 30/03/2023).
- [11] *Arret prématuré*. en. URL : <https://stanford.edu/~shervine/l/fr/teaching/cs-230/pense-bete-petites-astuces-apprentissage-profond> (visité le 10/06/2023).
- [12] *Arthrose Du Genou Cause Et Taitement*. en. 2019. URL : [https://oer.uclouvain.be/jspui/bitstream/20.500.12279/222/1/Arnaud%5C%20Deltour\\_Gonarthrose.pdf](https://oer.uclouvain.be/jspui/bitstream/20.500.12279/222/1/Arnaud%5C%20Deltour_Gonarthrose.pdf) (visité le 28/03/2023).
- [13] BOUCHEBAH. *Augmentation de données*. en. 2022. URL : <https://elearning.univ-bejaia.dz/course/view.php?id=4744> (visité le 15/05/2023).
- [14] BOUCHEBAH. *CNN*. en. 2022. URL : <https://elearning.univ-bejaia.dz/course/view.php?id=4744> (visité le 09/06/2023).
- [15] BOUCHEBAH. *Dropout*. en. 2022. URL : <https://elearning.univ-bejaia.dz/course/view.php?id=4744> (visité le 11/06/2023).
- [16] BOUCHEBAH. *Les réseaux de neurones*. en. 2022. URL : <https://elearning.univ-bejaia.dz/course/view.php?id=4744> (visité le 28/05/2023).
- [17] BOUCHEBAH. *Machine Learning*. en. 2022. URL : <https://elearning.univ-bejaia.dz/course/view.php?id=4744> (visité le 26/04/2023).
- [18] BOUCHEBAH. *RNP*. en. 2022. URL : <https://elearning.univ-bejaia.dz/course/view.php?id=4744> (visité le 29/05/2023).

- [21] *Comprendre les CNNs*. en. URL : <https://yannicksergeobam.medium.com/comprendre-les-r%C3%9C%5C%A9seaux-de-neurones-convolutifs-cnn-d5f14d963714> (visité le 17/05/2023).
- [22] *Data split "train, test, validation"*. en. URL : [https://mzuer.github.io/machine\\_learning/data\\_split](https://mzuer.github.io/machine_learning/data_split) (visité le 09/06/2023).
- [23] *Deep learning*. en. URL : <https://datascientest.com/deep-learning-definition> (visité le 09/06/2023).
- [24] *DenseNet*. en. URL : <https://sike6054.github.io/blog/paper/sixth-post/> (visité le 17/05/2023).
- [25] *Descente de gradient*. en. URL : <https://machinelearnia.com/descente-de-gradient/> (visité le 10/06/2023).
- [26] *Descente du gradient*. en. URL : <https://machinelearnia.com/descente-de-gradient/> (visité le 10/06/2023).
- [27] *Diagnostic de la gonarthrose sur le plan clinique*. en. URL : <https://www.passeportsante.net/fr/Maux/Problemes/Fiche.aspx?doc=gonarthrose> (visité le 30/03/2023).
- [28] *différents types d'arthrose*. en. Février 2022. URL : <https://www.lillyrhumatologie.fr/polyarthrite-rhumatoide/symptomes-et-articulations-touchees> (visité le 25/03/2023).
- [29] *différents types d'arthrose*. en. URL : <https://www.orliman.fr/votresante/gonarthrose/> (visité le 26/03/2023).
- [31] *Fréquence de l'arthrose*. en. URL : <https://www.pensersante.fr/arthrose-chiffres> (visité le 28/03/2023).
- [32] *Fully connected*. en. URL : <https://yannicksergeobam.medium.com/comprendre-les-r%C3%9C%5C%A9seaux-de-neurones-convolutifs-cnn-d5f14d963714> (visité le 17/05/2023).
- [33] et al. GRASSI A. *La contribution de la méniscectomie partielle à la laxité pré-opératoire et à la laxité après reconstruction anatomique du ligament croisé antérieur à faisceau unique*. Oct. 2019. URL : <https://journals.sagepub.com/doi/abs/10.1177/0363546519876648?%20journalCode=ajsb#bibliography> (visité le 29/03/2023).
- [38] *la structure interne des grands os*. en. URL : [https://www.researchgate.net/figure/Illustration-de-la-structure-interne-des-grands-os-Source-Pearson-Education-Inc\\_fig5\\_317302559](https://www.researchgate.net/figure/Illustration-de-la-structure-interne-des-grands-os-Source-Pearson-Education-Inc_fig5_317302559) (visité le 26/03/2023).
- [39] *les domaine d'IA*. en. URL : [https://blog-polytech-grenoble.fr/dm2i\\_et\\_ia](https://blog-polytech-grenoble.fr/dm2i_et_ia) (visité le 15/04/2023).
- [40] *les méthodes classique et DL*. en. URL : <https://datascientest.com/deep-learning-definition> (visité le 09/06/2023).
- [41] *Losses*. en. URL : <https://keras.io/api/losses/> (visité le 10/06/2023).
- [44] *Matplotlib*. en. URL : <https://pypi.org/project/matplotlib/> (visité le 12/06/2023).
- [46] *Métrique*. en. URL : <https://keras.io/api/Metric/> (visité le 10/06/2023).

- [47] *Modèle VGG*. en. URL : <https://iq.opengenus.org/different-types-of-cnn-models/> (visité le 17/05/2023).
- [49] *neurone biologique et artificiel*. en. URL : <https://www.google.com/search?q=neurone+biologique+et+neurones+artificiels> (visité le 14/05/2023).
- [50] *neurone formel*. en. URL : [https://www.researchgate.net/figure/Neurone-formel-Le-neurone-formel-recoit-un-ensemble-de-signaux-dentrees-x-i-et\\_fig21\\_33683726n](https://www.researchgate.net/figure/Neurone-formel-Le-neurone-formel-recoit-un-ensemble-de-signaux-dentrees-x-i-et_fig21_33683726n) (visité le 10/06/2023).
- [51] *Optimiseur Adam*. en. URL : <https://keras.io/api/optimizers/adam/> (visité le 10/06/2023).
- [54] *perceptron multicouche*. en. URL : [https://www.researchgate.net/figure/Le-perceptron-multicouches\\_fig6\\_30517821/download](https://www.researchgate.net/figure/Le-perceptron-multicouches_fig6_30517821/download) (visité le 14/05/2023).
- [55] *Python*. en. URL : <https://www.lebigdata.fr/python-langage> (visité le 12/06/2023).
- [56] *Sénario d'apprentissage avec renforcement*. en. URL : <https://france.devoteam.com/paroles-dexperts/learning-by-doing-apprentissage-par-renforcement/> (visité le 05/05/2023).
- [57] *Structure de l'os*. en. URL : <https://lagammevisco.fr/l-arthrose> (visité le 26/03/2023).
- [58] Mahdi TINHINANE. *Laboratoire Limed*. (Visité le 08/06/2023).
- [60] *Tout savoir sur Machine Learning*. en. URL : <https://www.talend.com/fr/resources/what-is-machine-learning/#:~:text=Talend%5C%20et%5C%20le%5C%20machine%5C%20learning,de%5C%20machine%5C%20learning%5C%20de%5C%20Spark> (visité le 15/04/2023).
- [61] *Transfert Learning*. en. URL : [https://keras.io/guides/transfer\\_learning/](https://keras.io/guides/transfer_learning/).
- [62] Mokri Mohammed ZAKARIA. *Classification des images avec les réseaux de neurones convolutionnels*. en. 2022. URL : <file:///C:/Users/user/Downloads/Classification-des-images-avec-les-reseaux-de-neurones.pdf> (visité le 28/04/2023).



# Résumé

L'ostéoarthrite (OA) est l'affection articulaire chronique la plus courante, affectant le mode de vie des individus, en particulier des adultes. Parmi les types de cette maladie osseuse figure l'arthrose du genou, caractérisée par une dégradation du cartilage et des modifications osseuses, qui provoquent des douleurs, des contraintes de mouvement et des anomalies. Pour résoudre ces problèmes, la détection précoce de l'arthrose du genou pourrait prévenir la destruction du cartilage et les problèmes causés par cette maladie. Par exemple, il est difficile de diagnostiquer l'arthrose à un stade précoce, car il a été suggéré que les premiers changements se produisent dans l'os sous-chondral avant l'apparition du rétrécissement de l'espace articulaire et des ostéophytes. Plusieurs techniques de Deep Learning sont disponibles pour l'analyse prédictive de cette pathologie. Dans notre étude, 28 ROI ont été localisés sur le genou (Tibia), afin de les classer en KL0 (sujet sain) ou KL2 (sujet arthros) à l'aide de réseaux neuronaux convolutionnels (CNN). Quatre modèles CNN ont été utilisés pour prédire la gonarthrose : VGG16, VGG19, ResNet152V2 et InceptionV3. L'expérience a été appliquée sur l'ensemble de données initiales de l'arthrose (OAI). Le classificateur VGG19 a fourni une précision supérieure de (73%) à celle des autres classificateurs.

---

**Mots clés :** L'arthrose, espace articulaire, ostéophytes, Deep Learning, ROIs, KL, CNN, VGG16, VGG19, ResNet152V2, InceptionV3, Prédiction, OAI.

---

# Abstract

Osteoarthritis (OA) is the most common chronic joint disease affecting the lifestyle of individuals, particularly adults. Among the types of this bone disease is osteoarthritis of the knee, characterized by cartilage degradation and bone changes, leading to pain, movement constraints and abnormalities. Early detection of osteoarthritis of the knee could help prevent the destruction of cartilage and the problems caused by this disease. For example, it is difficult to diagnose osteoarthritis at an early stage, as it has been suggested that the first changes occur in the subchondral bone before joint space narrowing and osteophytes appear. Several Deep Learning techniques are available for predictive analysis of this pathology. In our study, 28 ROIs were localized on the knee (Tibia), in order to classify them as KL0 (healthy subject) or KL2 (arthritic subject) using convolutional neural networks (CNN). Four CNN models were used to predict gonarthrosis : VGG16, VGG19, ResNet152V2 and InceptionV3. The experiment was applied to the osteoarthritis initiative dataset (OAI). The VGG19 classifier provided (73%) greater accuracy than the other classifiers.

---

**Keywords :** OsteoArthritis (OA), Joint space, Osteophytes, Deep Learning, ROIs, KL, CNN, VGG16, VGG19, ResNet152V2, InceptionV3, Prediction, OAI.

---