

الجمهورية الجزائرية الديمقراطية الشعبية

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

وزارة التعليم العالي والبحث العلمي

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

جامعة ابو بكر بالقائد - تلمسان

Université Aboubakr Belkaïd – Tlemcen – Faculté de TECHNOLOGIE



MEMOIRE

Présenté pour l'obtention du **diplôme** de **MASTER**

En : Génie Biomédical

Spécialité : Imagerie Médicale

Par : BENZIOUCHE Meriem & HAOUARI Aicha

Sujet

Détection et classification de l'arthrose par l'apprentissage profond

Soutenu publiquement, le 24/06/2025, devant le jury composé de :

M/BENGANA Abdelfatih	MCA	Université de Tlemcen	Président
M/ TAOULI Sidi Ahmed	MCB	Université de Tlemcen	Examinateur
Mme/ BELAROUCI Sara	MCB	Université de Tlemcen	Encadrante
Mlle/ ELAOUABER Zineb Aziza	Docteur	Université de Tlemcen	Co-Encadrante

Année universitaire : 2024 /2025

Dédicace

Tout d'abord, je tiens à remercier Dieu de m'avoir donné la force et le courage nécessaires pour mener à bien ce modeste travail.

Avec tout le respect qui m'anime et la sincérité de ma reconnaissance, je dédie l'obtention de mon diplôme et la joie qui l'accompagne :

À mon paradis sur terre, la prunelle de mes yeux, la source de ma joie, de mon amour et de mon bonheur, à ma lune et à ce fil d'espoir qui éclaire mon chemin... ma moitié, ma maman.

À celui qui m'a permis de devenir la femme que je suis aujourd'hui, À mon soutien, toujours à mes côtés pour m'encourager et me soutenir. ... mon papa.

À mon grand frère Kadirou, pour tout l'amour qu'il me porte, ainsi qu'à sa femme Fatima et leurs enfants Djalil et Adel.

À ma grande sœur Loubna, qui n'a jamais cessé de me conseiller, de m'encourager et de me soutenir tout au long de mes études, sans oublier son mari Abdou.

À ma marraine Souad, une seconde mère pour moi, toujours présente pour m'écouter, me conseiller et m'épauler. Merci d'être une présence si précieuse dans ma vie.

À tous les membres de ma grande famille : Mamie, Papi, mes tantes, mes oncles, mes cousins et cousines, pour leur amour et leur soutien.

À mon cher binôme Meriem, pour sa compréhension, sa patience, son esprit d'équipe et son soutien moral tout au long de ce projet.

À mes meilleures amies : Manel, Meriem, Houda, Khouloud, Chourouk, merci pour vos encouragements constants. Je vous souhaite encore plus de succès.

À toutes les personnes que j'aime et qui m'aiment, merci d'être dans ma vie.

Enfin, et surtout... Je veux me remercier. Je veux me remercier d'avoir cru en moi. Je veux me remercier d'avoir accompli tout ce travail. Je veux me remercier de n'avoir jamais abandonné.

Aticha

Dédicace

(وَأَخِرُ دَعْوَاهُمْ أَنْ الْحَمْدُ لِلَّهِ رَبِّ الْعَالَمِينَ)

حمد الله الذي ماتمَّ جُهد ولا ختم سعي إلا بفضلِهِ، الحمد لله على البلوغ ثم الحمد لله على التمام

À l'issue de ce parcours, je ressens le besoin profond de dédier ce travail à celles et ceux qui ont été ma lumière dans les moments d'obscurité, ma force dans les instants de doute, et mon repère lorsque tout semblait incertain.

Je dédie tout d'abord ce mémoire à ma famille, qui m'a entourée d'un amour inconditionnel, d'une patience infinie et d'une foi inébranlable. Merci à mes parents et à mes grands-parents pour leur présence discrète mais essentielle, pour chaque mot d'encouragement, chaque regard plein de confiance, et chaque sacrifice silencieux. Ce travail est aussi le vôtre.

Je pense également à mes proches, à mes amies, qui ont su m'apporter soutien, chaleur et réconfort. Vous avez cru en moi, même lorsque moi-même je n'y croyais plus. Votre bienveillance, vos mots sincères et vos gestes simples ont nourri ma volonté d'aller jusqu'au bout.

À toutes les personnes qui, de près ou de loin, ont croisé mon chemin et y ont laissé une empreinte positive : merci. Vous avez contribué, à votre manière, à cette réussite.

Enfin, je me dédie ce travail à moi-même. Pour avoir tenu bon lorsque le découragement menaçait, pour avoir poursuivi malgré les doutes, pour chaque pas, chaque page, chaque nuit de travail. Ce mémoire est le reflet d'un engagement personnel, d'une persévérance silencieuse et d'une volonté sereine de réussir.

Meriem

Remerciements

Tout d'abord, nous tenons à remercier Allah, qui nous a accordé la santé, la volonté et la patience nécessaires à la réalisation de ce travail.

Nous adressons nos sincères remerciements à notre encadrante Sara BELAROUCI pour sa patience, sa disponibilité et, surtout, ses judicieux conseils, qui ont grandement enrichi notre réflexion.

Nous exprimons également notre profonde reconnaissance à notre co-encadrante Zineb Aziza ELAOUABER pour son aide précieuse, sa compétence, son expertise, ainsi que pour la patience dont elle a fait preuve face à nos nombreuses interrogations.

Nous tenons aussi à remercier les membres du jury de soutenance Dr. BENGANA Abdelfatih et Dr. TAOULI Sidi Ahmed, dont l'examen attentif de notre mémoire et les suggestions pertinentes ont contribué de manière significative à l'amélioration de ce travail.

Nous remercions chaleureusement l'ensemble de l'équipe pédagogique de l'Université de Tlemcen, ainsi que les intervenants professionnels de notre formation, pour la qualité de l'enseignement théorique qu'ils nous ont dispensé.

Enfin, nous souhaitons remercier du fond du cœur toutes les personnes qui nous ont soutenus, accompagnés ou aidés, de près ou de loin, tout au long de la réalisation de ce mémoire.

Résumé

L'arthrose est une maladie articulaire chronique et évolutive, caractérisée par une dégradation progressive du cartilage, entraînant douleurs, raideurs et perte de mobilité. L'arthrose du genou, en particulier, est l'une des formes les plus courantes et invalidantes, nécessitant un diagnostic précoce pour une prise en charge efficace. Ce projet propose une approche automatisée reposant sur l'apprentissage profond pour la détection et la classification de cette affection à partir d'images radiographiques. Cinq modèles de réseaux neuronaux pré-entraînés (DenseNet121, MobileNetV2, ResNet50, InceptionV3 et EfficientNetB0) ont été évalués et comparés sur les bases de données publiques KOD-KL-2018 et AD-KAD, après un processus rigoureux de prétraitement des données. Les résultats obtenus sont particulièrement convaincants, avec DenseNet121 atteignant une précision de 96,14% sur KOD-KL-2018, tandis que DenseNet121 et InceptionV3 dépassent les 93% sur AD-KAD, surpassant ainsi les performances rapportées dans la littérature. Afin de renforcer la transparence des prédictions, la méthode d'explicabilité LIME a été intégrée. Par ailleurs, une interface graphique nommée ArthroScan a été conçue pour permettre une utilisation clinique simple et efficace de notre approche. Cette recherche confirme le potentiel de l'intelligence artificielle comme outil d'aide au diagnostic de l'arthrose du genou, en alliant précision, explicabilité et facilité d'intégration en pratique médicale.

Mots-clés: Arthrose, Arthrose du genou, Diagnostic précoce, Apprentissage profond, Apprentissage par transfert, Images radiographiques, Explicabilité, Aide au diagnostic.

Abstract

Osteoarthritis is a chronic and progressive joint disease, characterized by gradual cartilage degradation, leading to pain, stiffness, and loss of mobility. Knee osteoarthritis, in particular, is one of the most common and debilitating forms, necessitating early diagnosis for effective management. This project proposes an automated approach based on deep learning to detect and classify this condition from radiographic images. Five pre-trained neural network models (DenseNet121, MobileNetV2, ResNet50, InceptionV3, and EfficientNetB0) were evaluated and compared using the KOD-KL-2018 and AD-KAD datasets, following a rigorous data preprocessing pipeline. The results are particularly compelling, with DenseNet121 achieving an accuracy of 96.14% on KOD-KL-2018, while both DenseNet121 and InceptionV3 exceeded 93% on AD-KAD, surpassing reported performance in the literature. To enhance prediction transparency, the LIME explainability method was integrated. Furthermore, a graphical user interface named ArthroScan was designed to enable simple and effective clinical use of our approach. This research confirms the potential of artificial intelligence as a valuable diagnostic aid tool for knee osteoarthritis, combining precision, explainability, and ease of integration into medical practice.

Keywords: Osteoarthritis, Knee Osteoarthritis, Early diagnosis, Deep learning, Transfer learning, Radiographic images, Explainability, Diagnostic aid.

الملخص

التهاب المفاصل العظمي هو مرض مفصلي مزمن ومتطور يتسم بالتدهور التدريجي للغضروف، مما يؤدي إلى الألم والتصلب وفقدان القدرة على الحركة. ويُعد التهاب مفاصل الركبة العظمي، على وجه الخصوص، أحد أكثر أشكاله شيوعاً وإعاقةً، مما يستلزم تشخيصاً مبكراً لإدارة فعالة. يقترح هذا المشروع مقارنة آلية تعتمد على التعلم العميق للكشف عن هذا المرض وتصنيفه من صور الأشعة السينية. تم تقييم ومقارنة خمسة نماذج شبكات عصبية مدربة مسبقاً (DenseNet121، MobileNetV2، ResNet50، InceptionV3، EfficientNetB0) باستخدام قواعد بيانات KOD-KL-2018 و AD-KAD، بعد عملية صارمة لمعالجة البيانات الأولية.

النتائج التي تم الحصول عليها مقنعة بشكل خاص، حيث حقق DenseNet121 دقة بلغت 96.14% على KOD-KL-2018، بينما تجاوز كل من DenseNet121 و InceptionV3 نسبة 93% على AD-KAD، متجاوزين بذلك الأداء المبلغ عنه في الأدبيات. لتعزيز شفافية التنبؤات، تم دمج طريقة LIME التفسيرية. علاوة على ذلك، تم تصميم واجهة مستخدم رسومية تُدعى ArthroScan لتمكين الاستخدام السريبي البسيط والفعال لهذه النماذج. تؤكد هذه الدراسة على إمكانات الذكاء الاصطناعي كأداة قيمة للمساعدة في تشخيص التهاب مفاصل الركبة العظمي، حيث تجمع بين الدقة، والقابلية للتفسير، وسهولة الاندماج في الممارسة الطبية.

الكلمات المفتاحية: التهاب المفاصل العظمي، التهاب مفاصل الركبة العظمي، التشخيص المبكر، التعلم العميق، التعلم بالنقل، المعالجة المسبقة للبيانات، القابلية للتفسير، المساعدة التشخيصية

Table de matières

Dédicace.....	I
Dédicace.....	II
Remerciements.....	III
Résumé.....	IV
Abstract.....	V
الملخص.....	VI
Table de matières	XI
Liste des figures	XV
Liste des tableaux.....	XVII
Liste d'abréviations.....	XVIII
Introduction Générale	VIII
Chapitre 1 : Aspect médicale de l'arthrose	4
1. Introduction.....	5
2. Vue d'ensemble de l'arthrose.....	5
2.1 Définition.....	5
2.2 Cartilage.....	6
2.3 Types d'arthrose	7
2.3.1 Arthrose primaire (idiopathique).....	7
2.3.2 Arthrose secondaire.....	7
2.4 Physiopathologie	8
2.4.1 Articulations saines	8
2.4.2 Déclencheurs de l'arthrose.....	8
2.4.3 Mécanismes de dégradation	8
2.4.4 Changements tissulaires	8
3. Épidémiologie.....	9
4. Facteurs de risques.....	9
5. Signes et symptômes de l'arthrose	10
5.1 Signes cliniques	10
5.1.1 Douleur articulaire.....	10
5.1.2 Raideur articulaire.....	10

5.1.3	Limitation fonctionnelle.....	10
5.1.4	Déformations articulaires	10
5.1.5	Tuméfaction articulaire	11
5.1.6	Craquements et instabilité.....	11
5.1.7	Poussées congestives.....	11
5.2	Signes radiologiques.....	11
5.2.1	Pincement articulaire.....	11
5.2.2	Ostéophytes	11
5.2.3	Condensation osseuse sous-chondrale	11
5.2.4	Géodes.....	12
5.3	Signes biologiques.....	12
5.4	Signes arthroscopiques	12
6.	Localisations de l'arthrose	12
6.1	Arthrose Rachidienne	12
	Figure 1.3. Image radiographique de l'arthrose rachidienne	13
6.2	Arthrose des mains	13
6.3	Coxarthrose.....	14
6.4	Rhizarthrose (Arthrose du Pouce)	15
6.5	Gonarthrose	16
7.	Techniques d'exploration et de diagnostic	18
7.1	Examen Clinique	18
7.2	Examens complémentaires	18
7.2.1	La Radiographies.....	19
7.2.2	Scanner (Tomodensitométrie).....	19
7.2.3	Imagerie par résonance magnétique (IRM).....	20
7.2.4	Tests biologiques.....	20
8.	Traitement de l'arthrose.....	20
8.1	Hygiène de Vie et Rééducation Fonctionnelle	20
8.2	Traitement Médical.....	21
8.3	Gestes Locaux.....	21
8.4	Traitement chirurgical	21
9.	Conclusion	22

Chapitre 2 : Techniques d'apprentissage profond pour la détection de l'arthrose	26
1. Introduction.....	28
2. Intelligence artificielle	28
3. Apprentissage automatique	29
4. Apprentissage profond	30
5. Réseaux de neurones convolutifs.....	30
5.1 Les couches d'un réseau de neurones convolutif	31
5.1.1 Couche de Convolution.....	32
5.1.2 Fonctions d'activation.....	33
5.1.3 Couche de pooling	36
5.1.4 Couches entièrement connectées	36
5.1.5 Couche de Dropout	37
5.1.6 Couches de normalisation par lot.....	38
6. Fonction de perte.....	38
7. Algorithmes d'optimisation.....	39
8. Les Hyperparamètres en Apprentissage Profond	39
9. Apprentissage par transfert.....	40
10. Architectures de classification les plus connues	41
10.1 Architecture ResNet50	41
10.2 Architecture DenseNet121	43
10.3 Architecture MobileNetV2	44
10.4 InceptionV3	45
10.5 EfficientNetB0.....	46
11 Métriques d'Évaluation.....	47
11.1 Matrice de confusion	47
11.2 Taux de Classification Correcte (Accuracy)	47
11.3 Rappel (Recall)	47
11.4 Précision (Precision).....	47
11.5 F1-Score.....	48
11.6 Courbe ROC et AUC.....	48
12 L'état de l'art	48
13 Conclusion.....	50

Chapitre 3 : Classification Automatique de l'Arthrose du Genou : Méthodes et Résultats	26
1. Introduction.....	54
2. Environnement de développement et outils d'implémentation	55
2.1 Python.....	55
2.2 Kaggle.....	55
3. Description des bases de données	55
3.1 Jeu de données : Knee Osteoarthritis Dataset with KL Grading–2018 (KOD-KL-2018).....	56
3.2 Jeu de données: Annotated Dataset for Knee Arthritis Detection (AD-KAD).....	56
4. Méthodes proposées.....	57
4.1 Prétraitement des données	58
4.1.1 Normalisation de données.....	58
4.1.2 Équilibrage des classes	59
4.1.3 Augmentation de données.....	60
4.2 Classification des stades de l'arthrose.....	61
4.2.1 Notre DenseNet121 adapté pour la Classification de l'Arthrose	61
4.2.2 Notre Resnet50 adapté pour la Classification de l'Arthrose	62
4.2.3 Notre Efficientnetb0 adapté pour la Classification de l'Arthrose	63
4.2.4 Notre Inceptionv3 adapté pour la Classification de l'Arthrose	64
4.2.5 Notre Mobilenetv2 adapté pour la Classification de l'Arthrose.....	65
4.3 Explicabilité du modèle.....	66
5. Résultats expérimentaux et discussion.....	67
5.1 Hyperparamètres d'optimisation	67
5.2 Contribution 1 : Optimisation de la classification de l'arthrose du genou sur la base de données KOD-KL-2018	67
5.2.1 Évaluation comparative de la classification en 5 classes.....	68
5.2.2 Expérimentation avec un équilibrage partiel des données.....	70
5.2.3 Reconfiguration de la classification en 4 classes.....	71
5.2.4 Analyse comparative des différentes configurations	76
5.2.5 Évaluation des Prédictions sur la Base de Test.....	76
5.2.6 Comparaison de nos résultats avec l'état de l'art.....	77
5.3 Contribution 2 : Validation sur le jeu de données annoté pour la détection de l'arthrose du genou (AD-KAD).....	78
5.3.1 Évaluation des modèles et effet du prétraitement sur AD-KAD	78

5.3.2 Comparaison de nos résultats avec l'état de l'art.....	81
5.4 Contribution 3 : Analyse de l'interprétabilité des modèles.....	82
5.5 Contribution 4 : Développement d'une interface graphique interactive	82
6. Conclusion	85
Conclusion Générale.....	51
Conclusion.....	92
Perspectives.....	92
Références bibliographiques.....	86

Liste des figures

Figure 1. 1. La progression de l’arthrose du genou avec le temps.....	6
Figure 1.2. Les trois types du cartilage	7
Figure 1.3. Image radiographique de l’arthrose rachidienne	13
Figure 1.4. Image radiographique de l’arthrose des mains.....	14
Figure 1.5. Image radiographique de l’arthrose coxarthrose	15
Figure 1.6. Image radiographique de l’arthrose du pouce	16
Figure 1.7. Représentation anatomique des stades de la gonarthrose.....	17
Figure 1.8. Représentation radiographique des différents stades de la gonarthrose.....	18
Figure 1.9. Radiographie du genou pathologique.....	19
Figure 1.10. Scanner du genou	19
Figure 1.11. IRM du genou.....	20
Figure 2.1. La différence entre l'apprentissage automatique et l'apprentissage profond	30
Figure 2.2. Illustration d’un exemple de CNN pour la classification des images.....	31
Figure 2.3. Exemple d’un CNN pour la classification des images d’arthrose.....	32
Figure 2.4. Exemple d’opération de convolution.....	33
Figure 2.5. Le principe de fonctionnement du ReLU	34
Figure 2.6. Les courbes des fonctions d’activation.....	35
Figure 2.7. Types de pooling.....	36
Figure 2.8. Couche entièrement connectée.....	37
Figure 2.9. Réseau avant et après régularisation par Dropout.....	38
Figure 2.10. Exemple d’apprentissage par transfert utilisant un réseau de neurones convolutif	41
Figure 2.11. Architectures ResNet50.....	43
Figure 2.12. Architecture DenseNet121.....	44
Figure 2.13. Architecture MobileNetV2.....	45
Figure 2.14. Architecture InceptionV3.....	46
Figure 2.15. Architecture EfficientNetB0.....	46
Figure 2.16. Matrice de confusion.....	47
Figure 3.1. Exemples d’images issues de la base de données KOD-KL-2018.....	56
Figure 3.2. Exemples d’images issues de la base de données AD-KAD.....	57
Figure 3.3. Organigramme général de notre méthode de classification de l’arthrose.....	58
Figure 3.4. Illustration des images radiographiques avant et après l’étape de normalisation.....	59
Figure 3.5. Répartition des classes dans la base de données KOD-KL-2018.....	60
Figure 3.6. Répartition des classes dans la base de données AD-KAD avant et après l’étape d’équilibrage... ..	60
Figure 3.7. Exemples d’images après application de transformations géométriques.....	61
Figure 3.8. Notre architecture personnalisée de DenseNet121.....	62
Figure 3.9. Notre architecture personnalisée de ResNet50.....	63
Figure 3.10. Notre architecture personnalisée d’EfficientNetB0.....	64
Figure 3.11. Notre architecture personnalisée d’InceptionV3.....	65
Figure 3.12. Notre architecture personnalisée de Mobilenetv2.....	66
Figure 3.13. Matrices de confusion des différents modèles après application du prétraitement... ..	69
Figure 3.14. Distribution des Classes Équilibrées et Matrice de Confusion (DenseNet121)	70
Figure 3.15. Matrices de confusion des différents modèles après prétraitement sur KOD-KL2018	70

(classification en 4 classes).....	73
Figure 3.16. Performances des modèles après prétraitement : Matrices de confusion pour la classification en 4 classes sur le jeu de données KOD-KL-2018.....	75
Figure 3.17. Résultats de prédiction pour la base de données KOD-KL-2018.....	77
Figure 3.18. Performances des modèles après prétraitement : Matrices de confusion pour la classification sur le jeu de données AD-KAD.....	80
Figure 3.19. Visualisation de l'interprétabilité des prédictions par LIME pour les différentes classes de sévérité de l'arthrose du genou (0 à 4).....	82
Figure 3.20. Interface de Connexion du Médecin.....	83
Figure 3.21. Saisie des Informations Patient.....	84
Figure 3.22. Chargement de la Radiographie.....	84
Figure 3.23. Affichage de l'Analyse et des Résultats de Classification.....	85

Liste des tableaux

Tableau 1.1. Stades de l'arthrose rachidienne.....	13
Tableau 1.2. Stades de l'arthrose des mains.....	14
Tableau 1.3. Stades de l'arthrose coxarthrose.....	15
Tableau 1.4. Stades de l'arthrose du pouce.....	16
Tableau 1.5. Stades de l'arthrose gonarthrose.....	17
Tableau 3.1. Classification de la base de données KOD-KL-2018.....	56
Tableau 3.2. Classification de la base de données AD-KAD.....	57
Tableau 3.3. Hyperparamètres optimisés pour l'entraînement du modèle.....	67
Tableau 3.4. Évaluation des performances des modèles sur KOD-KL-2018 (5 classes) avant et après prétraitement.....	68
Tableau 3.5. Performances des modèles sur KOD-KL-2018 (5 classes) après prétraitement.....	70
Tableau 3.6. Évaluation des performances des modèles sur KOD-KL-2018 (4 classes) avant et après prétraitement.....	72
Tableau 3.7. Comparaison des performances des modèles sur KOD-KL-2018 (4 classes) avant et après l'étape de prétraitement.....	74
Tableau 3.8. Évaluation comparative de nos méthodes de classification par rapport aux approches existantes sur le jeu de données KOD-KL-2018.....	77
Tableau 3.9. Comparaison des performances des modèles sur le jeu de données AD-KAD avant et après prétraitement.....	79
Tableau 3.10. Évaluation comparative de nos méthodes de classification par rapport aux approches existantes sur le jeu de données AD-KAD.....	81

Liste d'abréviations

- AINS** : Anti-inflammatoires non stéroïdiens
- Acc** : Accuracy (Exactitude)
- AdaGrad** : Adaptive Gradient Algorithm
- Adam** : Adaptive Moment Estimation
- AD-KAD** : Annotated Dataset for Knee Arthritis Detection
- AUC** : Area Under the Curve
- CLAHE** : Contrast Limited Adaptive Histogram Equalization
- CNN** : Réseaux de neurones convolutifs
- CRP** : Protéine C-réactive
- FP** : Faux positif
- FN** : Faux négatif
- IA** : Intelligence Artificielle
- IPD** : Nodosités de Heberden
- IPP** : Nodosités de Bouchard
- KL** : Kellgren-Lawrence
- KOA** : L'arthrose du genou
- K-NN** : k-Nearest Neighbors
- KOD-KL-2018** : Knee Osteoarthritis Dataset with KL Grading–2018
- NAG** : Nesterov Accelerated Gradient
- OA-MEN** : Osteoarthritis Multi-Modal and Explainable Network
- PR** : Polyarthrite rhumatoïde
- ROC** : Receiver Operating Characteristic curve
- ReLU** : Rectified Linear Unit
- RMSProp** : Root Mean Square Propagation
- RP** : Rhumatisme psoriasique
- SGD** : Stochastic Gradient Descent
- SGDM** : Momentum
- Se** : Sensibilité
- SMOTE** : Synthetic Minority Oversampling Technique

SVM : Support Vector Machine

Sp : Spécificité

VP : Vrai positif

VN : Vrai négatif

VS : Vitesse de sédimentation

XAI : Intelligence Artificielle explicable

YOLOv8 : You Only Look Once version 8

YOLOv8x-cls : Variante du modèle YOLOv8

Introduction Générale

Contexte

L'arthrose est une affection articulaire dégénérative chronique, représente un défi majeur de santé publique à l'échelle mondiale. Caractérisée par la dégradation du cartilage et des tissus articulaires, elle est une cause fréquente de douleur chronique et de réduction significative de la mobilité, affectant des millions d'individus. Bien que l'arthrose puisse toucher diverses articulations, l'arthrose du genou est particulièrement prévalente et impactante, souvent associée au vieillissement et à l'augmentation des facteurs de risque comme l'obésité. La détection précoce et la classification précise de sa sévérité sont essentielles pour une prise en charge thérapeutique efficace, visant à ralentir sa progression et à améliorer la qualité de vie des patients.

Le diagnostic de l'arthrose repose généralement sur l'interprétation visuelle des radiographies par des radiologues. Toutefois, cette méthode peut entraîner des divergences d'interprétation, des délais prolongés et une charge de travail importante, notamment dans les contextes où les ressources spécialisées sont limitées. L'intégration de l'intelligence artificielle (IA), en particulier de l'apprentissage profond, constitue une avancée prometteuse pour pallier ces limitations. Ces technologies ont démontré leur capacité à analyser et classer les images médicales avec une grande précision, favorisant ainsi le développement de systèmes d'aide à la décision plus performants et moins dépendants de la subjectivité humaine.

Problématique

Dans un contexte où des outils de diagnostic rapides, objectifs et fiables pour l'arthrose sont de plus en plus nécessaires, notre projet de fin d'études explore l'utilisation des réseaux de neurones convolutionnels (CNN), une technologie essentielle de l'apprentissage profond. L'objectif est de développer un système automatisé capable d'identifier et de classer les stades de l'arthrose du genou à partir d'images radiographiques, avec un haut niveau de précision et une bonne capacité de généralisation.

Notre approche repose sur l'apprentissage par transfert, en tirant parti de cinq architectures de modèles pré-entraînés : DenseNet121, ResNet50, InceptionV3, MobileNetV2 et EfficientNetB0. Ce choix permet d'optimiser les performances tout en réduisant le besoin en données annotées. Néanmoins, plusieurs défis subsistent, notamment le déséquilibre entre les classes de sévérité de l'arthrose et la nécessité d'un prétraitement rigoureux des données.

Ces enjeux posent des questions clés sur l'optimisation des modèles pour garantir une précision diagnostique élevée et une robustesse suffisante dans des environnements cliniques variés.

Motivation et Objectifs

Notre motivation principale découle de la volonté de contribuer à l'amélioration des pratiques diagnostiques en radiologie, spécifiquement pour l'arthrose du genou. L'intégration de l'IA vise à alléger la charge de travail des radiologues, à réduire les erreurs diagnostiques liées à la variabilité humaine et à accélérer le processus diagnostique, ce qui est crucial pour une prise en charge précoce des patients.

Ce projet vise à évaluer l'efficacité des modèles d'apprentissage profond, en particulier via l'apprentissage par transfert, pour la classification de l'arthrose du genou à partir d'images radiographiques. Notre recherche aspire à diminuer les erreurs de diagnostic et à accélérer les décisions cliniques en dotant les rhumatologues d'outils automatisés et précis. En nous appuyant sur les bases de données KOD-KL-2018 (Knee Osteoarthritis Dataset with KL Grading–2018) et AD-KAD (Annotated Dataset for Knee Arthritis Detection), l'étude compare plusieurs architectures pré-entraînées et explore des techniques de prétraitement et d'équilibrage pour améliorer leur performance.

Les objectifs spécifiques incluent :

- La mise en place d'un pipeline complet de détection et classification,
- L'optimisation des CNN par diverses techniques,
- L'évaluation de leur capacité de généralisation sur des ensembles de données différents.
- Le développement d'outils d'interprétabilité,
- Et la création d'une interface graphique adaptée aux professionnels de santé.

Contributions

Ce projet apporte plusieurs contributions clés dans le domaine du diagnostic assisté par ordinateur de l'arthrose du genou :

- Optimisation de la classification de l'arthrose du genou sur la base de données KOD-KL-2018, en explorant diverses configurations et stratégies de prétraitement.
- Validation sur le jeu de données annoté pour la détection de l'arthrose du genou (AD-KAD), en démontrant la robustesse et la capacité de généralisation de nos modèles.
- Analyse de l'explicabilité et l'interprétabilité des modèles. Notre travail inclut l'utilisation d'outils comme LIME pour comprendre les prédictions du modèle.
- Développement d'une interface graphique interactive (ArthroScan) facilitant l'utilisation de l'outil par les professionnels de santé dans un environnement clinique réel.

Organisation du mémoire

Ce mémoire est structuré en plusieurs chapitres :

Le *Chapitre 1 : Aspect médical de l'arthrose* : introduit le contexte médical de l'arthrose, couvrant sa physiopathologie, son épidémiologie, ses facteurs de risque, ses signes et ses localisations. IL détaille également les techniques d'exploration et de diagnostic, ainsi que les traitements associés.

Le *Chapitre 2 : Techniques d'apprentissage profond pour la détection de l'arthrose* : explore les fondements de l'intelligence artificielle et de l'apprentissage automatique, en se concentrant sur l'apprentissage profond, les réseaux de neurones convolutifs, l'apprentissage par transfert et les métriques d'évaluation, tout en abordant les avancées récentes dans la détection et la classification automatisée de l'arthrose.

Le *Chapitre 3 : Classification Automatique de l'Arthrose du Genou : Méthodes et Résultats* : détaille les bases de données utilisées, l'approche méthodologique, les résultats des classifieurs optimisées, l'explicabilité des modèles et la conception de l'interface graphique.

Enfin, une *conclusion générale* synthétisera les principaux résultats de nos expérimentations et présentera aussi les pistes de recherche futures pour approfondir et étendre ce projet de fin d'étude.

Chapitre 1 : Aspect médicale de l'arthrose

1. Introduction

L'arthrose est une pathologie articulaire dégénérative fréquente affectant les articulations et les tissus adjacents, représentant aujourd'hui un enjeu majeur de santé publique à l'échelle mondiale. Avec l'allongement de l'espérance de vie, le vieillissement du système osseux s'accroît, favorisant la dégradation progressive des articulations et impactant fortement la qualité de vie.

Ce chapitre explorera les divers aspects médicaux de l'arthrose, incluant sa définition, ses types, sa physiopathologie, son épidémiologie, ainsi que les facteurs de risque, les signes et les symptômes associés, et ses localisations. Les techniques de diagnostic et les options thérapeutiques disponibles seront également abordées, en soulignant l'importance d'une approche personnalisée pour améliorer le bien-être des patients atteints d'arthrose.

2. Vue d'ensemble de l'arthrose

Dans cette partie, nous allons explorer les fondements de l'arthrose à travers sa définition, ses mécanismes clés et sa typologie. Cette mise au point est essentielle pour comprendre les développements ultérieurs sur le diagnostic et la prise en charge de cette pathologie.

2.1 Définition

L'arthrose est une maladie dégénérative chronique des articulations, marquée par une détérioration progressive et irréversible du cartilage. Elle constitue la principale cause de handicap chez les adultes d'âge moyen et demeure la pathologie articulaire la plus fréquente après 65 ans. En plus du cartilage, elle affecte également l'os sous-chondral ainsi que le liquide et la membrane synoviaux [1].

Cette maladie se manifeste par une dégradation et une perte de cartilage, des modifications hypertrophiques de l'os avec formation d'ostéophytes, un remodelage osseux et, fréquemment, une inflammation chronique. Les articulations les plus fréquemment touchées sont celles qui supportent le poids du corps, notamment la hanche, le genou, les articulations interphalangiennes proximale et distale, ainsi que les facettes articulaires vertébrales. Plus rarement, l'arthrose peut également affecter la cheville, le poignet ou l'épaule [1].

Elle résulte d'une combinaison de processus mécaniques, cellulaires et biochimiques qui perturbent le remodelage normal du cartilage, entraînant des altérations dégénératives et une réponse réparatrice anormale [1]. L'évolution chronologique de l'arthrose du genou est illustrée par la Figure 1.1.




Figure 1.1. La progression de l'arthrose du genou avec le temps

2.2 Cartilage

Le cartilage est un tissu conjonctif dense et souple, dépourvu de vaisseaux sanguins et de terminaisons nerveuses. Il joue un rôle essentiel d'amortisseur entre les os en absorbant les chocs. En raison de sa faible capacité de régénération, sa cicatrisation est lente. Avec l'âge, le cartilage tend à se calcifier, ce qui réduit son élasticité. Dans le cadre de l'arthrose, ce tissu se détériore progressivement, compromettant ainsi la fonction articulaire.

La matrice cartilagineuse est produite par les chondroblastes, tandis que les chondrocytes, enfermés dans de petites cavités appelées lacunes, y survivent grâce à la diffusion des nutriments contenus dans le liquide interstitiel [2].

Le cartilage se compose de différentes molécules, telles que [2] :

- Sulfate de chondroïtine, classé comme un glycosaminoglycane.
- L'acide hyaluronique.
- La chondronectine, dont le rôle est d'assurer l'adhérence.
- Des fibres de collagène.

Il existe plusieurs types de cartilage, chacun présentant une structure et une fonction bien spécifiques [2] :

- a) **Le cartilage hyalin** est le type de cartilage le plus courant. Il contient beaucoup de collagène, ce qui lui donne à la fois solidité et élasticité. Il se trouve aux extrémités des os, où il facilite les mouvements en amortissant les chocs. Il est aussi présent dans le nez, la trachée, les côtes et chez l'embryon, où il sert de modèle pour la formation des os.
- b) **Le cartilage élastique**, qui contient davantage de fibres élastiques, se trouve notamment dans l'oreille externe.

- c) **Le cartilage fibreux**, plus ferme, se situe là où le cartilage hyalin se lie aux tendons ou aux ligaments. On le trouve notamment au niveau des disques intervertébraux et des ménisques des genoux.

La Figure 1.2 illustre les trois types de cartilage.




Figure 1.2. Les trois types du cartilage

2.3 Types d'arthrose

L'arthrose peut être classée en deux grandes catégories :

2.3.1 Arthrose primaire (idiopathique)

Cette forme d'arthrose, dont la cause exacte de reste inconnue, représente la majorité des cas diagnostiqués. Elle peut être localisée, touchant des articulations telles que celles de la main, du genou ou de la hanche, ou généralisée qui se manifeste de manière plus diffuse, affectant plusieurs articulations simultanément [3].

2.3.2 Arthrose secondaire

L'arthrose est dite secondaire lorsqu'elle résulte d'une cause bien déterminée. Parmi les facteurs pouvant en être à l'origine, nous citons [3] :

- Une infection articulaire.
- Une anomalie congénitale de l'articulation.
- Un traumatisme ou une lésion articulaire.
- Un trouble métabolique, comme l'hémochromatose (excès de fer) ou la maladie de Wilson (accumulation de cuivre dans le foie).
- Une maladie inflammatoire ou métabolique ayant altéré le cartilage, telle que la polyarthrite rhumatoïde ou la goutte.

2.4 Physiopathologie

Afin de mieux comprendre l'évolution de l'arthrose et ses répercussions sur les articulations, cette partie décrit les principales étapes de la physiopathologie de l'arthrose, depuis le fonctionnement normal de l'articulation jusqu'aux altérations pathologiques.

2.4.1 Articulations saines

Les articulations saines assurent des mouvements fluides, sans frottement, et résistent à l'usure en cas d'utilisation normale. Leur bon fonctionnement repose sur le cartilage hyalin, un tissu avasculaire et non innervé, composé à 95 % d'eau et de matrice extracellulaire, et à seulement 5% de chondrocytes, qui se renouvellent très lentement. Ce cartilage fonctionne grâce aux pressions exercées lors des mouvements : la compression expulse les liquides vers l'extérieur, et la décompression permet leur retour, permettant ainsi l'apport des nutriments essentiels [3].

2.4.2 Déclencheurs de l'arthrose

L'arthrose peut être déclenchée par des facteurs mécaniques, comme une déchirure méniscale, ou par la diffusion de substances inflammatoires provenant de la synoviale vers le cartilage. Ce dernier peut être fragilisé aussi à travers des troubles métaboliques. L'obésité, en particulier, joue un rôle aggravant en combinant surcharge mécanique et sécrétion d'adipokines (comme la leptine et l'adipsine), qui endommagent le cartilage et l'os sous-jacent [3].

2.4.3 Mécanismes de dégradation

Lorsque des lésions apparaissent, les chondrocytes s'activent pour réparer le cartilage, augmentant la production de protéoglycanes et de collagène. Cependant, cette réparation est accompagnée d'une production excessive d'enzymes dégradant le cartilage et de cytokines inflammatoires. Ces médiateurs entraînent une inflammation chronique qui stimule davantage les chondrocytes et les cellules synoviales, contribuant à la destruction progressive du cartilage. A un stade avancé, les chondrocytes subissent une apoptose, et l'os sous-jacent devient éburné et scléreux [3].

2.4.4 Changements tissulaires

L'arthrose affecte tous les tissus articulaires, ainsi que certains tissus périphériques. L'os sous-chondral devient plus dense (scléreux), puis peut présenter des zones de nécrose et former des kystes. En réponse, l'organisme produit des ostéophytes en périphérie, dans une tentative de stabilisation. Le cartilage peut s'épaissir temporairement avant de se fissurer et de s'user. La membrane synoviale s'épaissit légèrement, et produit un liquide plus abondant mais moins visqueux, ce qui perturbe la lubrification. Ces modifications entraînent une réduction de la mobilité, un affaiblissement des muscles environnants, et une altération des ménisques du genou, qui peuvent se fissurer et provoquer des douleurs [3].

3. Épidémiologie

En 2019, l'arthrose constituait une affection très répandue à l'échelle mondiale, touchant environ 528 millions d'individus, soit une augmentation substantielle de 113 % par rapport à 1990. Les personnes âgées de plus de 55 ans représentaient 73 % des cas, et les femmes étaient plus concernées que les hommes, représentant 60 % des patients. L'arthrose du genou restait la forme la plus fréquemment diagnostiquée. Parmi les individus touchés, environ 344 millions présentaient des formes modérées à sévères, soulignant un besoin croissant en services de rééducation [4].

Concernant la distribution par sexe, la prévalence de l'arthrose était similaire chez les hommes et les femmes avant l'âge de 50 ans. Cependant, après cet âge, les femmes étaient plus fréquemment touchées, en particulier après la ménopause [4].

En termes de localisation, l'arthrose affectait principalement les mains (35 à 45 %), les genoux (30 %), le rachis cervical et lombaire (15 à 23 %), et les hanches (10 %). Enfin, une forme généralisée de la maladie était observée chez environ 45 % des patients. [4]

4. Facteurs de risques

Plusieurs facteurs de risque interagissent avec une susceptibilité intrinsèque du cartilage, contribuant au développement de l'arthrose. Parmi eux, nous citons [5] :

- *L'âge* : Le risque s'accroît avec l'âge. L'arthrose est rare avant 40 ans, mais sa prévalence s'accroît nettement après 50 ans, en raison du vieillissement des tissus articulaires.
- *La surcharge articulaire* : L'excès de poids, le port de charges lourdes, une activité physique excessive ou la pratique incorrecte de certains sports peuvent intensifier les contraintes mécaniques sur les articulations et favoriser l'arthrose.
- *L'hérédité* : Des antécédents familiaux d'arthrose, en particulier l'arthrose digitale, peuvent augmenter la prédisposition à cette maladie
- *Les facteurs hormonaux* : Les femmes sont plus susceptibles de développer l'arthrose, avec une différence notable après la ménopause, probablement liée aux changements hormonaux, en particulier la baisse des œstrogènes.
- *Les affections cardiométaboliques* : Des pathologies telles que le diabète, l'hypertension artérielle ou la dyslipidémie sont associées à une inflammation chronique de bas grade pouvant contribuer à la dégradation du cartilage et d'augmenter le risque d'apparition d'arthrose.
- *Les pathologies articulaires préexistantes* : Des maladies comme la chondrocalcinose, la goutte, la polyarthrite rhumatoïde (PR) et le rhumatisme psoriasique (RP) peuvent induire des lésions articulaires favorisant le développement de l'arthrose.

- *Les maladies osseuses adjacentes à l'articulation* : L'ostéonécrose aseptique, qui affecte l'os situé sous le cartilage, constitue également un facteur de risque.
- *Les anomalies anatomiques et séquelles de traumatismes* : Des déviations de l'alignement des membres (telles que le genou varum ou valgum), des dysplasies de la hanche ou encore des conséquences de traumatismes articulaires (fractures, entorses, luxations, méniscectomie) peuvent entraîner des déséquilibres articulaires et favoriser l'apparition de l'arthrose.

5. Signes et symptômes de l'arthrose

L'arthrose se manifeste par un ensemble de symptômes cliniques caractéristiques et peut être confirmée par des signes radiologiques spécifiques.

5.1 Signes cliniques

5.1.1 Douleur articulaire

La douleur articulaire typique de l'arthrose est de nature mécanique, survenant ou s'intensifiant lors des efforts et diminuant au repos. Elle se distingue également par son installation progressive et son augmentation d'intensité avec le temps. La localisation de la douleur dépend de l'articulation atteinte, soit du genou, de la hanche, des mains, ou d'autres [5].

5.1.2 Raideur articulaire

Un autre signe clinique de l'arthrose est la raideur articulaire, qui se fait sentir principalement après des périodes de repos, notamment au réveil. Cette sensation de difficulté à bouger l'articulation est habituellement brève, durant moins de 30 minutes, mais elle a tendance à devenir plus marquée avec l'évolution de la maladie [5].

5.1.3 Limitation fonctionnelle

La limitation fonctionnelle est une conséquence fréquente de l'arthrose, se traduisant par une réduction de l'amplitude des mouvements au niveau des articulations atteintes. Cette restriction peut entraîner des difficultés importantes dans l'accomplissement des activités quotidiennes, telles que monter les escaliers ou se lever d'une chaise, affectant ainsi l'autonomie et la qualité de vie de la personne [5].

5.1.4 Déformations articulaires

Aux stades plus avancés de l'arthrose, des déformations des articulations peuvent devenir apparentes, prenant la forme de nodosités. Deux types principaux sont observés au niveau des doigts [5] :

- Les *nodosités d'Heberden*, situées sur les articulations interphalangiennes distales (IPD).
- Les *nodosités de Bouchard*, qui se forment sur les articulations interphalangiennes proximales (IPP). Ces excroissances osseuses sont des signes visibles de la progression de la maladie.

5.1.5 Tuméfaction articulaire

La tuméfaction articulaire, ou sensation de gonflement, est un autre signe de cette pathologie. Elle peut être causée par la présence d'ostéophytes, ces excroissances osseuses caractéristiques de la maladie, ou par un épanchement synovial, c'est-à-dire une accumulation de liquide dans l'articulation. Il est important de noter que cette tuméfaction n'est pas systématiquement liée à une inflammation significative de l'articulation [5].

5.1.6 Craquements et instabilité

Les personnes atteintes d'arthrose peuvent également ressentir des craquements ou une sensation de frottement lors des mouvements. De plus, au niveau des articulations portantes, telles que le genou, une sensation d'instabilité ou de "dérobement" peut survenir, témoignant d'une perte de la stabilité normale de l'articulation [5].

5.1.7 Poussées congestives

L'arthrose peut aussi se traduire par des poussées congestives, correspondant à des épisodes d'intensification de la douleur à caractère inflammatoire. Ces épisodes s'accompagnent généralement d'un gonflement articulaire, lié à un épanchement de liquide synovial. Ils surviennent le plus souvent à la suite d'une activité excessive ou d'un traumatisme local de l'articulation concernée [5].

5.2 Signes radiologiques

5.2.1 Pincement articulaire

L'un des signes radiologiques caractéristiques de l'arthrose est le pincement articulaire, qui se manifeste par une réduction de l'espace interosseux. Ce phénomène résulte directement de la dégradation et de la perte du cartilage. Il est généralement plus marqué dans les zones de l'articulation soumises aux contraintes mécaniques très importantes [5].

5.2.2 Ostéophytes

Un autre signe radiologique caractéristique de l'arthrose est la présence d'ostéophytes. Il s'agit d'excroissances osseuses qui se développent sur les bords des articulations et qui sont aisément identifiables lors d'un examen radiographique standard [5].

5.2.3 Condensation osseuse sous-chondrale

La condensation osseuse sous-chondrale est un autre signe radiologique. Elle se manifeste par une augmentation de la densité de l'os qui se trouve immédiatement sous le cartilage affecté. Ce phénomène est interprété comme une réaction de l'os face aux contraintes mécaniques accrues résultant de la dégradation du cartilage [5].

5.2.4 Géodes

Les géodes, qui sont des cavités de type kystique se développant dans l'os sous-chondral, peuvent également être observées lors d'un examen radiographique chez les personnes atteintes d'arthrose. Leur formation est supposément due à une pression excessive ou à une réaction inflammatoire circonscrite à cette région osseuse située sous le cartilage [5].

5.3 Signes biologiques

L'arthrose, contrairement aux maladies inflammatoires systémiques, présente généralement une biologie normale. Les examens révèlent une vitesse de sédimentation (VS) et une protéine C-réactive (CRP) normales. De plus, le liquide synovial est clair et visqueux avec un faible taux de cellules ($< 1\ 000/\text{mm}^3$) reflétant une atteinte mécanique [5].

5.4 Signes arthroscopiques

L'arthroscopie est une technique médicale qui permet d'observer directement l'intérieur d'une articulation, comme le genou, à l'aide d'un arthroscope. Elle permet d'évaluer avec précision l'état du cartilage et d'autres structures internes. Les signes arthroscopiques correspondent aux anomalies visibles telles que l'usure, les fissures et l'inflammation aident à diagnostiquer et à mieux comprendre la gravité de maladies articulaires comme l'arthrose [5].

6. Localisations de l'arthrose

L'arthrose peut affecter différentes articulations du corps. Sa classification repose principalement sur la localisation des zones touchées, ce qui permet de distinguer plusieurs formes cliniques, dont certaines sont particulièrement fréquentes.

6.1 Arthrose Rachidienne

L'arthrose rachidienne est une pathologie dégénérative touchant les articulations de la colonne vertébrale. Son apparition est fréquemment due à l'usure naturelle liée à l'avancée en âge, à des traumatismes ou à des anomalies posturales, impactant principalement les disques intervertébraux et les articulations facettaires. L'origine de cette condition peut être *primaire*, survenant avec le vieillissement sans cause spécifique identifiée, ou *secondaire*, résultant de lésions antérieures, de malpositions ou de troubles métaboliques [6].

La progression de l'arthrose rachidienne est caractérisée par différents stades, chacun présentant des changements physiopathologiques, des symptômes et des implications cliniques spécifiques, qui sont présentés dans le Tableau 1.1 ci-dessous [6].

Stade	Changements physiopathologiques	Symptômes	Implication clinique
Stade 1 : Changements Minimes	Changements radiologiques minimes, pincements intervertébraux légers.	Douleurs occasionnelles après des efforts, souvent asymptomatique	Surveillance et conseils sur l'activité physique.
Stade 2 : Apparition d'Ostéophytes	Apparition d'ostéophytes, pincements intervertébraux plus marqués,	Apparition d'ostéophytes, douleurs intermittentes	Traitements symptomatiques, physiothérapie recommandée
Stade 3 : Raideur Persistante	Raideur persistante, pincement discal plus prononcé, ostéophytes plus importants.	Douleurs fréquentes, limitation fonctionnelle significative	Options de traitement plus agressives, évaluation pour infiltrations
Stade 4 : Limitation Sévère	Limitation sévère des mouvements, déformations possibles,	Douleurs chroniques, incapacité à effectuer des activités quotidiennes	Chirurgie souvent nécessaire, comme une fusion vertébrale

Tableau 1.1. Stades de l'arthrose rachidienne.

La figure 1.3 ci-dessous illustre une visualisation radiographique du rachis




Figure 1.3. Image radiographique de l'arthrose rachidienne

6.2 Arthrose des mains

L'arthrose de la main est une maladie dégénérative chronique qui affecte les articulations des doigts et du poignet. Elle est souvent associée à des facteurs héréditaires, ainsi qu'à la répétition de gestes mécaniques. Ce type peut être *primaire*, généralement liée à une prédisposition génétique sans cause précise identifiée, ou *secondaire*, survenant suite à des mouvements répétés ou à des traumatismes localisés au niveau de la main [6].

Les différents stades d'évolution de cette affection, caractérisés par des changements physiopathologiques, des symptômes et des implications cliniques, sont détaillés dans le Tableau 1.2 qui suit [6].

Stade	Changements physiopathologiques	Symptômes	Implication clinique
Stade 1 : Début	Usure légère du cartilage dans les articulations des doigts.	Douleurs légères et intermittentes, surtout après l'utilisation.	Surveillance et conseils sur l'utilisation des mains
Stade 2 : Modérée	Pincement léger des espaces articulaires, Apparition de nodules (comme les nodules de Heberden)	Douleurs plus fréquentes, raideur matinale	Physiothérapie et exercices pour maintenir la mobilité
Stade 3 : Avancée	Pincement articulaire plus prononcé, Dégradation plus marquée du cartilage.	Douleurs chroniques, déformation des doigts	Traitements symptomatiques et éventuellement chirurgie
Stade 4 : Terminale	Cartilage absent, déformations osseuses importantes.	Douleurs sévères et mobilité très limitée des doigts	Chirurgie pour améliorer la fonction, comme une arthroplastie

Tableau 1.2. Stades de l'arthrose des mains.

La figure 1.4 ci-dessous illustre une image radiographique des mains.



Figure 1.4. Image radiographique de l'arthrose des mains

6.3 Coxarthrose

La coxarthrose, ou arthrose de la hanche, correspond à une dégradation progressive de l'articulation coxo-fémorale, souvent liée au vieillissement, à un excès de poids ou à des antécédents traumatiques. Elle peut être d'origine primitive, généralement associée à l'âge avancé et à l'obésité, ou secondaire, consécutive à un traumatisme, à des malformations congénitales ou à certaines pathologies comme la maladie de Paget [6].

Son évolution s'effectue en plusieurs stades, chacun se distinguant par des changements physiopathologiques, des symptômes spécifiques et des implications cliniques, comme présenté dans le Tableau 1.3 [6].

Stade	Changements physiopathologiques	Symptômes	Implication clinique
Stade 1 : Début de la Coxarthrose	Usure légère du cartilage, parfois asymptomatique. Modifications radiologiques minime	Douleurs légères après l'effort, souvent au niveau de l'aîne.	Surveillance et éducation sur les activités à éviter.
Stade 2 : Coxarthrose Modérée	Pincement modéré de l'espace articulaire. Apparition d'ostéophytes.	Douleurs plus fréquentes, surtout lors de l'activité. Raideur après le repos.	Traitements médicamenteux et physiothérapie recommandés.
Stade 3 : Coxarthrose Avancée	Pincement articulaire prononcé. Dégradation significative du cartilage.	Douleurs chroniques, limitation de la mobilité. Difficultés à marcher ou à se lever.	Possibilité d'infiltrations et d'évaluations chirurgicales.
Stade 4 : Coxarthrose Terminale	Cartilage absent, contact osseux direct. Déformation de l'articulation.	Douleurs sévères et mobilité très limitée.	Chirurgie souvent nécessaire, typiquement une arthroplastie de la hanche.

Tableau 1.3. Stades de l'arthrose coxarthrose

La figure 1.5 présente une radiographie illustrant un cas de coxarthrose.




Figure 1.5. Image radiographique de l'arthrose coxarthrose

6.4 Rhizarthrose (Arthrose du Pouce)

L'arthrose du pouce, ou rhizarthrose, constitue une forme spécifique de cette affection dégénérative, localisée au niveau de l'articulation trapézo-métacarpienne, à la base du pouce. Elle se manifeste par une altération progressive du cartilage articulaire, entraînant des douleurs et de perte de mobilité. Son origine peut être *primitive*, souvent associée au vieillissement et à une prédisposition génétique sans cause clairement identifiée, ou *secondaire*, résultant d'un usage excessif de

l'articulation, notamment lors de gestes répétitifs, d'activités professionnelles ou sportives, ou encore à la suite de traumatismes du pouce [6].

Les différents stades évolutifs de la rhizarthrose, caractérisées par leurs changements physiologiques, symptômes et implications cliniques, sont présentés en détail dans le Tableau 1.4 [6].

Stade	Changements physiopathologiques	Symptômes	Implication clinique
Stade 1 : Début de la Rhizarthrose	Usure légère du cartilage, souvent asymptomatique.	Douleurs occasionnelles à la base du pouce, souvent après une activité précise.	Surveillance et conseils sur l'évitement des mouvements douloureux.
Stade 2 : Rhizarthrose Modérée	Pincement léger de l'articulation carpo-métacarpienne, apparition d'ostéophytes.	Douleurs plus fréquentes, surtout lors de la préhension. Raideur du pouce.	Traitements médicamenteux et orthèses recommandés.
Stade 3 : Rhizarthrose Avancée	Pincement articulaire marqué, dégradation significative du cartilage.	Douleurs persistantes, limitation fonctionnelle, difficulté à saisir des objets.	Évaluations pour infiltrations et considérations chirurgicales.
Stade 4 : Rhizarthrose Terminale	Cartilage absent, contact osseux direct, déformations osseuses.	Douleurs sévères, mobilité très limitée.	Chirurgie possible, comme une arthroplastie.

Tableau 1.4. Stades de l'arthrose du pouce

La figure 1.6 illustre une image radiographique du pouce.



Figure 1.6. Image radiographique de l'arthrose du pouce

6.5 Gonarthrose

La gonarthrose désigne l'arthrose qui affecte l'articulation du genou. Son développement est souvent influencé par l'âge, des anomalies biomécaniques du genou ou des antécédents traumatiques. Elle peut être de nature *primitive*, apparaissant le plus souvent de manière bilatérale chez les femmes

âgées de 50 à 60 ans, en lien avec des facteurs de risque tels que l'obésité. En revanche, la forme *secondaire* résulte généralement de malformations congénitales ou acquises (comme le genou varum ou valgum), ou encore de traumatismes antérieurs [6].

L'évolution de la gonarthrose se déroule en plusieurs stades, chacun étant caractérisé par des changements physiopathologiques, des symptômes spécifiques et des implications cliniques, comme détaillé dans le Tableau 1.5 [6].

Stade	Changements physiopathologiques	Symptômes	Implication clinique
Stade 1 : Début de la gonarthrose	Début de l'usure du cartilage, souvent asymptomatique. Légères modifications radiologiques, parfois invisibles.	Douleurs légères après un effort ou une activité prolongée. Raideur matinale passagère.	Surveillance et conseils sur l'activité physique.
Stade 2 : Gonarthrose modérée	Pincement articulaire plus prononcé. Dégradation importante du cartilage.	Douleurs plus fréquentes pendant l'activité. Raideur matinale plus marquée, mais généralement de courte durée.	Traitements symptomatiques et exercices de renforcement musculaire.
Stade 3 : Gonarthrose avancée	Pincement articulaire prononcé. Dégradation significative du cartilage.	Douleurs chroniques et persistantes. Mobilité limitée, avec des difficultés à effectuer des mouvements quotidiens.	Options de traitement plus agressives, incluant infiltrations et éventuellement chirurgie.
Stade 4 : Gonarthrose terminale	Cartilage pratiquement absent, contact osseux direct. Déformations osseuses significatives.	Douleurs sévères et invalidantes. Mobilité très réduite.	Chirurgie souvent nécessaire, comme une arthroplastie du genou.

Tableau 1.5. Stades de l'arthrose gonarthrose

Les stades évolutifs de la gonarthrose sont présentés dans les figures 1.7 et 1.8 suivantes :

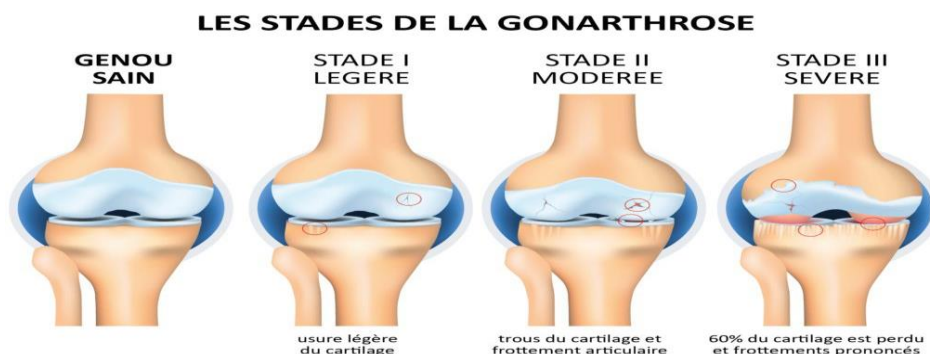


Figure 1.7. Représentation anatomique des stades de la gonarthrose



Figure 1.8. Représentation radiographique des différents stades de la gonarthrose

7. Techniques d'exploration et de diagnostic

Le diagnostic de l'arthrose repose sur une approche clinique rigoureuse, complétée par diverses techniques d'imagerie et d'exploration permettant de confirmer la pathologie, d'en évaluer la gravité et d'orienter la prise en charge.

7.1 Examen Clinique

Le diagnostic de l'arthrose débute systématiquement par un examen clinique approfondi visant à évaluer la symptomatologie du patient. Cet examen prend en compte la localisation (ou topographie) des douleurs, ainsi que l'inspection de l'articulation afin de rechercher un gonflement, d'une déformation, de nodules ou un épanchement liquidien. Des manipulations et palpations articulaires sont également réalisées afin de détecter une douleur à la pression et/ou à la mobilisation, tout en évaluant l'amplitude des mouvements [6].

L'interrogatoire constitue une étape cruciale du diagnostic. Il permet de caractériser précisément la douleur en évaluant son intensité, son ancienneté, son mode d'évolution (aigu, progressive, intermittente, déclenchée ou non par les mouvements) ainsi que son rythme (mécanique ou inflammatoire, incluant les douleurs nocturnes ou de dérouillage matinal). Cette étape permet également de recueillir des informations sur les antécédents du patient (traumatismes, injections intra- ou péri-articulaires, atteintes articulaires préexistantes, antécédents familiaux d'arthrose (notamment digitale), obésité, activité sportive) et d'analyser son activité professionnelle [6].

7.2 Examens complémentaires

Des examens complémentaires sont nécessaires pour confirmer les données recueillies lors de l'examen clinique et pour affiner le diagnostic. Plusieurs techniques peuvent être mises en œuvre afin de mieux évaluer l'atteinte articulaire, Parmi ceux-ci, on trouve [5]

7.2.1 La Radiographies

La radiographie constitue l'examen de première intention dans le diagnostic de l'arthrose, en raison de sa rapidité, de son faible coût et de sa large disponibilité. Elle permet d'obtenir une première évaluation efficace de l'atteinte articulaire. La figure 1.9 suivante présente une visualisation radiographique du genou :




Figure 1.9. Radiographie du genou pathologique

Les signes radiographiques caractéristiques de l'arthrose comprennent [5] :

- *Pincement de l'interligne articulaire* : réduction de l'espace entre les os, particulièrement dans les zones soumises à des pressions ;
- *Ostéophytes* : excroissances osseuses qui se forment sur les bords des articulations ;
- *Géodes* : cavités sous-chondrales pouvant apparaître, bien qu'elles soient moins fréquentes ;
- *Condensation de l'os sous-chondral* : augmentation de la densité osseuse située sous le cartilage.

7.2.2 Scanner (Tomodensitométrie)

Le scanner est une technique d'imagerie qui utilise les rayons X pour produire des images en coupes transversales du corps. Il se révèle particulièrement utile pour l'évaluation des anomalies osseuses complexes et offre une analyse détaillée et précise de la morphologie osseuse. Cette précision en fait un outil précieux dans la planification d'interventions chirurgicales [5].

La figure suivante présente une visualisation par scanner du genou :



Figure 1.10. Scanner du genou

7.2.3 Imagerie par résonance magnétique (IRM)

L'IRM est une technique d'imagerie avancée qui utilise un champ magnétique et des ondes radio pour produire des images très détaillées et de haute résolution. Elle permet une visualisation précise des tissus mous, tels que le cartilage, les ligaments et la membrane synoviale. L'IRM permet également de détecter des lésions cartilagineuses non visibles à la radiographie, d'identifier une inflammation synoviale et de repérer d'éventuels débris cartilagineux [5].



Figure 1.11. IRM du genou

7.2.4 Tests biologiques

Les tests biologiques sont réalisés afin d'exclure d'autres pathologies inflammatoires susceptibles de simuler les symptômes de l'arthrose. Les tests courants comprennent [5] :

- **Vitesse de sédimentation (VS)** : Cet examen mesure le niveau d'inflammation dans l'organisme. Généralement, la VS est normale en cas d'arthrose.
- **Protéine C-réactive (CRP)** : C'est un indicateur de l'inflammation. Les taux de CRP sont habituellement normaux chez les patients atteints d'arthrose.
- **Tests spécifiques** : Ces analyses permettent de détecter des maladies telles que la polyarthrite rhumatoïde (recherche du facteur rhumatoïde, des anticorps anti-CCP).

8. Traitement de l'arthrose

Le traitement de l'arthrose vise à soulager la douleur, maintenir la mobilité et améliorer la qualité de vie. Il comprend différentes approches :

8.1 Hygiène de Vie et Rééducation Fonctionnelle

Un ensemble des mesures et pratiques visant à améliorer la gestion quotidienne de l'arthrose. Ces approches comprennent [7] :

- *Réduction des contraintes articulaires* : Perte de poids et limitation des stations debout prolongées.
- *Utilisation de cannes* : Rapport d'une canne du côté sain afin de soulager l'articulation atteinte.

- *Correction des inégalités de longueur des membres* : Utilisation de semelles orthopédiques si nécessaire.
- *Aménagement du poste de travail* : Adaptation de l'environnement professionnel pour minimiser les contraintes articulaires.
- *Activités physiques recommandées* : Privilégier les activités à faible impact comme la natation et la marche, tout en évitant les sports violents.
- *Rééducation fonctionnelle* : Balnéothérapie et physiothérapie pour maintenir et améliorer la mobilité articulaire.

8.2 Traitement Médical

Un ensemble de médicaments utilisés pour soulager la douleur et gérer l'inflammation associée à l'arthrose. Ce traitement inclut [7] :

- *Antidouleurs* : Antalgiques de palier 1 ou 2 pour un soulagement temporaire de la douleur.
- *Anti-inflammatoires non stéroïdiens (AINS)* : Prescrits lors des poussées inflammatoires douloureuses.
- *Les chondroprotecteurs*: Utilisés pour leur effet antalgique retardé.

8.3 Gestes Locaux

Des procédures interventionnelles ciblées visant à soulager la douleur et l'inflammation directement au niveau de l'articulation atteinte. Ces gestes comprennent [7] :

- *Infiltrations de corticoïdes* : Utilisées lors des poussées congestives et inflammatoires.
- *Infiltrations d'acide hyaluronique* : Visent à obtenir un effet antalgique plus durable.

8.4 Traitement chirurgical

Un ensemble des interventions chirurgicales envisagées pour traiter l'arthrose, allant de la correction des déformations au remplacement articulaire. Ces interventions comprennent [7] :

- *Intervention préventive* : Elle peut être envisagée chez les jeunes patients présentant des déformations importantes afin de prévenir ou de retarder la progression de l'arthrose. Il est généralement préférable d'éviter la pose de prothèses en cas d'arthrose peu symptomatique.
- *Chirurgie conservatrice* : Des ostéotomies peuvent être réalisées pour corriger les déformations des genoux et des hanches, dans le but de réaligner l'articulation et de soulager la douleur.
- *Chirurgie palliative* : L'arthroplastie, qui consiste au remplacement de l'articulation par une prothèse, est envisagée pour les formes évoluées de l'arthrose. Elle offre d'excellents résultats en termes de réduction de la douleur et permet une récupération progressive de la mobilité.

9. Conclusion

L'arthrose est une pathologie articulaire dégénérative de nature complexe, qui ne se limite pas aux effets du vieillissement. Elle résulte de mécanismes variés, incluant des facteurs mécaniques, inflammatoires et métaboliques. Cette maladie altère considérablement la qualité de vie et représente un enjeu majeur de santé publique. Les examens d'imagerie, tels que la radiographie et l'IRM, sont essentiels pour un diagnostic précoce et un suivi efficace. Dans un contexte de prévalence croissante liée notamment au vieillissement de la population, une prise en charge intégrée, combinant prévention, diagnostic précis et traitements adaptés, est indispensable.

Dans ce chapitre, nous avons présenté une vue d'ensemble complète de l'arthrose, en abordant ses mécanismes physiopathologiques, ses différentes localisations, ses manifestations cliniques ainsi que les techniques d'exploration et les options thérapeutiques disponibles.

Le chapitre suivant présente un état de l'art des approches basées sur l'apprentissage profond et l'imagerie médicale, en vue d'améliorer la détection et la classification de l'arthrose.

Chapitre 2 : Techniques d'apprentissage profond pour la détection de l'arthrose

1. Introduction

La classification de l'arthrose représente un défi majeur en imagerie médicale, notamment dans l'analyse des radiographies articulaires. L'essor de l'intelligence artificielle, et plus particulièrement de l'apprentissage profond, a permis de développer des outils capables d'améliorer la détection et l'évaluation de cette pathologie. Parmi ces outils, les réseaux de neurones convolutifs (CNN) se distinguent par leur capacité à extraire automatiquement des caractéristiques visuelles pertinentes, facilitant l'identification des signes radiologiques de l'arthrose.

Pour optimiser les performances tout en limitant les besoins en données annotées, l'apprentissage par transfert est fréquemment utilisé. Cette technique consiste à réutiliser des modèles pré-entraînés sur de grandes bases d'images, comme ResNet, DenseNet ou MobileNet, afin d'adapter rapidement ces architectures à la classification de cette maladie.

Ce chapitre débute par une introduction à l'intelligence artificielle, suivie des fondements de l'apprentissage automatique et de l'apprentissage profond. Il examine ensuite en détail les réseaux de neurones convolutifs ainsi que l'utilisation de l'apprentissage par transfert. L'état de l'art est analysé pour mettre en lumière les avancées récentes dans l'application de ces approches à la détection et à la classification de l'arthrose, avant de se conclure par une synthèse générale.

2. Intelligence artificielle

L'intelligence artificielle (IA) est une branche de l'informatique qui se concentre sur la création de machines capables d'effectuer des tâches requérant habituellement l'intelligence humaine, telles que la reconnaissance vocale et faciale, la prise de décision, la résolution de problèmes, l'apprentissage et la compréhension du langage naturel [8].

L'IA repose sur des algorithmes et des modèles mathématiques qui imitent les processus cognitifs humains, et qui permettent aux systèmes d'apprendre à partir des données afin de s'améliorer progressivement. Il existe principalement deux types d'IA [8] :

- *L'IA faible (ou étroite)* : elle est conçue pour accomplir une tâche spécifique, comme la reconnaissance d'images, la traduction automatique ou les assistants vocaux. Ce type fonctionne dans un cadre bien défini et ne peut pas effectuer de tâches en dehors de son domaine de compétence.
- *L'IA forte* : elle fait référence à une intelligence artificielle capable d'exécuter l'ensemble des tâches cognitives qu'un être humain est capable d'accomplir. Elle impliquerait une forme de conscience, de compréhension et de raisonnement autonome.

L'intelligence artificielle est aujourd'hui utilisée dans de nombreux domaines, tels que la médecine, la finance, ou encore la sécurité, où elle permet d'automatiser des processus, d'analyser de grandes quantités de données et d'améliorer la prise de décision [8].

3. Apprentissage automatique

L'apprentissage automatique, ou machine learning, est une branche de l'intelligence artificielle qui vise à développer des algorithmes capables d'apprendre à partir de données existantes et d'expériences accumulées. Ces algorithmes peuvent améliorer leurs performances au fil du temps sans être explicitement programmés, ce qui leur permet de générer des prédictions fiables sur de nouvelles données [9].

L'enjeu majeur est de rendre les machines capables d'apprendre de façon autonome, en ajustant leur comportement sans intervention humaine, afin de se rapprocher d'une forme d'intelligence comparable à celle de l'être humain [10].

Il existe plusieurs types d'apprentissage automatique, classés selon leurs mécanismes d'apprentissage et le type de données utilisées, notamment :

- **Apprentissage supervisé** : Cette méthode repose sur l'entraînement d'un modèle à partir de données étiquetées, c'est-à-dire pour lesquelles les sorties attendues sont connues. Elle est couramment utilisée pour des tâches de classification ou de régression, où le système apprend à associer des entrées à des sorties précises [10].
- **Apprentissage non supervisé** : Contrairement à l'approche supervisée, cette méthode ne nécessite pas de données étiquetées. Le modèle reçoit uniquement des données d'entrée sans indication sur les résultats attendus. Elle est principalement utilisée pour des techniques de regroupement (clustering) ou de détection de structures sous-jacentes dans les données [10].
- **Apprentissage semi-supervisé** : Cette approche hybride combine les principes de l'apprentissage supervisé et non supervisé. Elle est particulièrement utile lorsque seules quelques données sont étiquetées, tandis que la majorité du jeu de données ne l'est pas. Dans ce cas, le modèle est d'abord entraîné sur la portion annotée, puis il exploite les données non étiquetées en s'appuyant sur les connaissances acquises au cours de la première phase [11].
- **Apprentissage par renforcement** : Ce type d'apprentissage repose sur l'interaction d'un agent avec son environnement. Le modèle apprend par essais et erreurs, recevant des récompenses ou des pénalités en fonction de la qualité de ses actions. Au fil des itérations, il ajuste ses paramètres de manière à maximiser une fonction de récompense [10].

4. Apprentissage profond

L'apprentissage profond, ou Deep learning, constitue une branche avancée de l'apprentissage automatique. Il repose sur l'utilisation d'architectures à plusieurs couches (ou niveaux) permettant de modéliser des relations complexes entre les données. Grâce à ces structures profondes, il devient possible pour la machine d'apprendre de manière autonome à partir de données massives, entraînant des réseaux de neurones. Le Deep learning se situe à la croisée de plusieurs disciplines : réseaux de neurones, modélisation graphique, optimisation, intelligence artificielle, reconnaissance de formes et traitement du signal [12].

La figure 2.1 suivante illustre la différence entre l'apprentissage automatique et l'apprentissage profond :

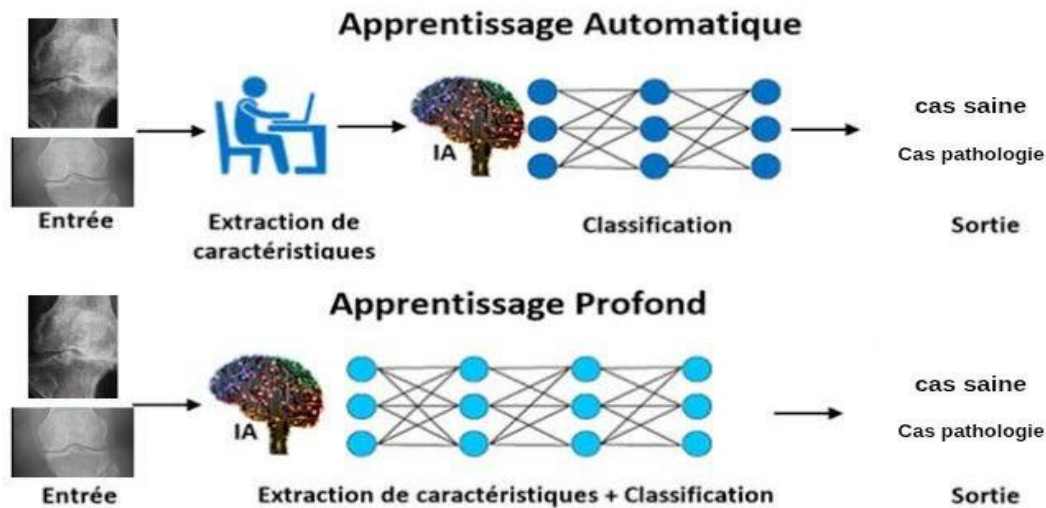


Figure 2.1. La différence entre l'apprentissage automatique et l'apprentissage profond

L'apprentissage profond repose sur un réseau de neurones artificiels profonds, inspiré du fonctionnement du cerveau humain. Ce réseau est constitué de dizaines, voire de centaines de « couches » de neurones, chacune recevant et interprétant les informations provenant de la couche précédente [12]. Le système apprendra progressivement, par exemple, à identifier des caractéristiques subtiles dans une image radiologique avant de diagnostiquer une pathologie spécifique, ou à détecter des anomalies dans des signaux cardiaques de base avant de classifier le type d'arythmie.

5. Réseaux de neurones convolutifs

Les réseaux de neurones convolutifs (CNN) sont des architectures avancées de réseaux de neurones artificiels, composées de multiples couches cachées, chacune apprenant à abstraire les données à un

niveau différent. Leur application a considérablement amélioré l'analyse d'images médicales et la détection de pathologies, atteignant des performances supérieures à celles des humains dans des tâches spécifiques [11].

Un CNN est principalement constitué de couches de convolution, appliquant des filtres pour extraire des caractéristiques, et de couches de pooling, réduisant la dimensionnalité tout en conservant les informations essentielles. Après l'extraction des caractéristiques, la sortie de la dernière couche de convolution est aplatie en un vecteur de caractéristiques, servant d'entrée à des couches entièrement connectées pour la classification des images. Le réseau est entraîné en ajustant les poids des connexions via un algorithme de rétropropagation du gradient, afin de minimiser la fonction de perte. Cette approche permet aux CNN de devenir des outils cruciaux dans le traitement d'images et l'analyse de données complexes [11].

La figure 2.2. suivante illustre les différentes couches d'un réseau CNN, en précisant sa structure ainsi que le rôle de chaque couche dans le fonctionnement global du réseau.

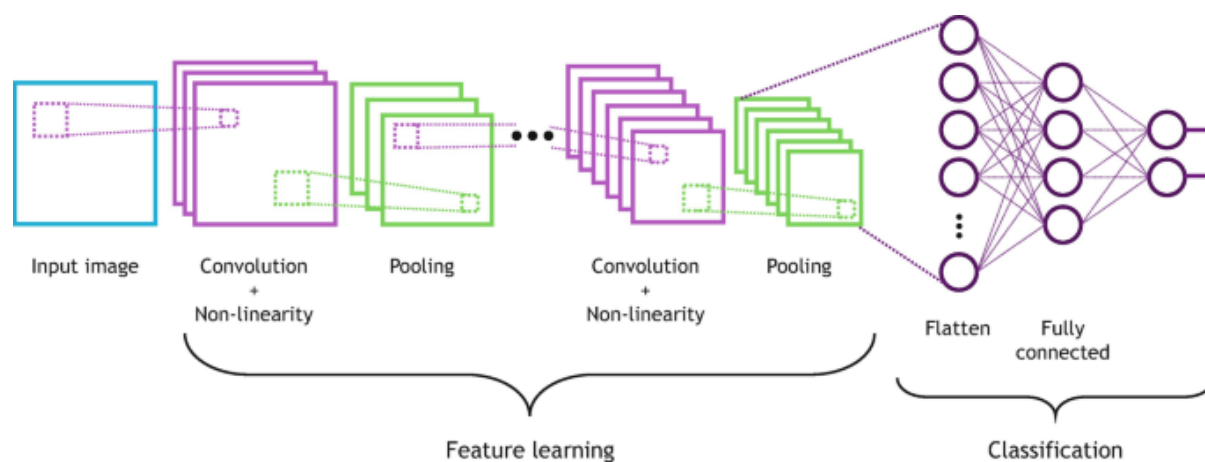


Figure 2.2. Illustration d'un exemple de CNN pour la classification des images

5.1 Les couches d'un réseau de neurones convolutif

Les couches d'un CNN sont les éléments fondamentaux qui permettent au modèle d'accomplir ses tâches complexes et intelligentes sur les images. Chaque couche joue un rôle essentiel dans la chaîne de traitement des données. Elles peuvent être classées en plusieurs catégories en fonction de leur fonction spécifique [11].

Les CNN se composent généralement de quatre couches principales : la couche de convolution, la couche de correction (fonction d'activation), la couche de pooling et la couche entièrement connectée.

Il existe d'autres types de couches, telles que la couche de normalisation et la couche de régularisation (dropout). Dans les parties suivantes, nous allons décrire les différentes couches employées pour la construction des CNN [11].

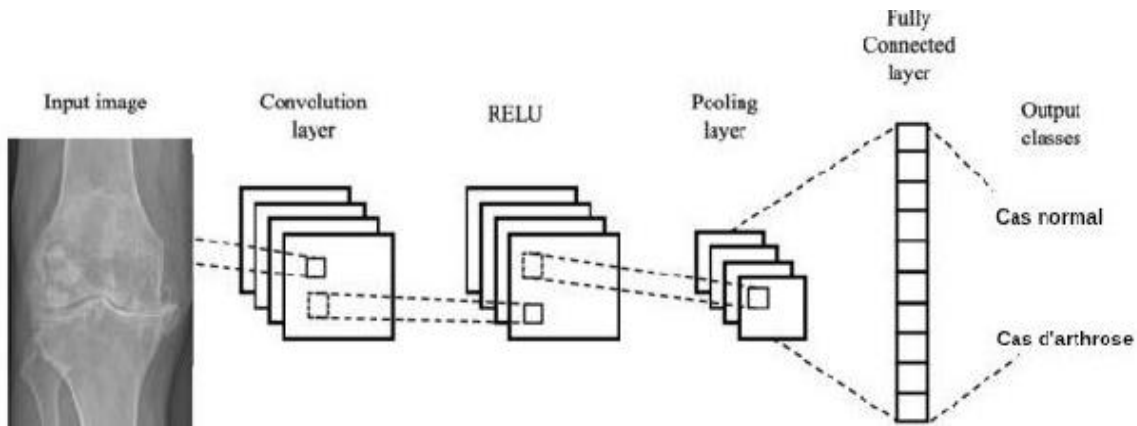


Figure 2.3. Exemple d'un CNN pour la classification des images d'arthrose.

5.1.1 Couche de Convolution

Les couches de convolution constituent le cœur des réseaux de neurones convolutifs. Leur fonction principale est d'extraire des caractéristiques des données d'entrée, généralement des images. Elles remplissent différentes fonctions, notamment [13] :

- *Filtrage convolutionnel* : Les couches de convolution appliquent des filtres (ou noyaux) sur l'image d'entrée. Un filtre est une petite matrice, souvent de taille 3x3 ou 5x5, qui glisse (ou "convolue") sur l'image.
- *Détection de caractéristiques* : Chaque filtre est conçu pour détecter un type spécifique de caractéristique, comme des bords, des textures ou des motifs particuliers. Par exemple, un filtre peut identifier les bords horizontaux, tandis qu'un autre peut repérer les bords verticaux.
- *Cartes de caractéristiques* : L'application d'un filtre sur l'image produit une carte de caractéristiques. Chaque couche de convolution génère plusieurs cartes de caractéristiques, chacune correspondant à un filtre différent.
- *Non-linéarité* : Après l'application du filtre, une fonction d'activation non linéaire, telle que ReLU (Rectified Linear Unit), est fréquemment appliquée pour introduire de la non-linéarité dans le modèle. Cela permet de modéliser des relations plus complexes au sein des données.




Figure 2.4. Exemple d'opération de convolution

5.1.2 Fonctions d'activation

À la suite de chaque opération de convolution, une fonction d'activation est appliquée aux cartes de caractéristiques afin d'introduire de la non-linéarité dans le réseau. Cela permet au modèle de mieux représenter des relations complexes entre les données d'entrée et de sortie. Parmi les fonctions les plus fréquemment utilisées, on trouve : la sigmoïde, tanh, ReLU, Leaky ReLU et Softmax [11].

- **Fonction sigmoïde** : cette fonction transforme une valeur réelle en un intervalle compris entre 0 et 1. En raison de sa forme en "S", elle est particulièrement utile pour normaliser les sorties des neurones, notamment dans les problèmes de classification binaire. Elle est définie mathématiquement par l'équation suivante [11] :

$$Sigmoïde(z) = \frac{1}{1+e^{-z}} \quad (2.1)$$

Où z est la valeur d'entrée. Si z est positif, la fonction tend vers 1 ; sinon, elle tend vers 0 lorsque z est négatif.

- **Fonction tanh (tangente hyperbolique)** : elle est similaire à la fonction sigmoïde, mais possède une plage de sortie plus large. Elle transforme une valeur réelle en une valeur comprise entre -1 et 1. La fonction tanh est définie comme suit [11] :

$$Tanh(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}} \quad (2.2)$$

- **Fonction ReLU (Rectified Linear Unit – Unité Linéaire Rectifiée)** : cette fonction d'activation est largement utilisée dans les réseaux de neurones profonds en raison de sa simplicité, de sa

rapidité de calcul et de son efficacité sur de nombreuses tâches. Elle est définie comme une fonction non linéaire réelle, donnée par [11] :

$$ReLU(z) = \max(0, z) \quad (2.3)$$

Cette fonction transforme toutes les valeurs négatives en entrée en zéros, ce qui peut limiter l'activité du réseau de neurones en désactivant certains neurones, entraînant ainsi une possible diminution de la précision. Pour remédier à cet inconvénient, plusieurs variantes de la fonction ReLU ont été développées, telles que la fonction Leaky ReLU, qui introduit une légère pente pour les valeurs négatives [11].

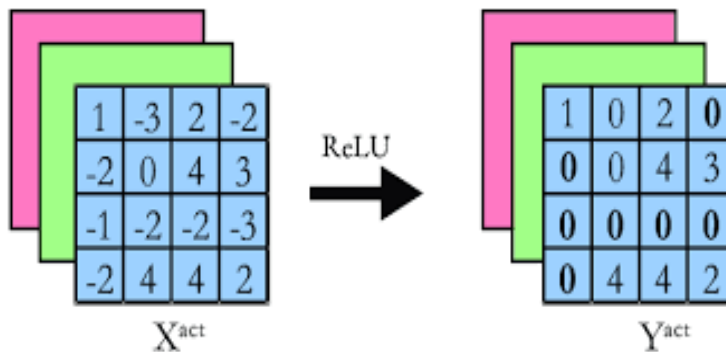


Figure 2.5. Le principe de fonctionnement du ReLU

- **Fonction Leaky ReLU (Leaky Rectified Linear Unit)** : cette fonction est une version modifiée de la fonction ReLU classique, conçue pour atténuer le problème des neurones inactifs. Plutôt que d'annuler complètement les valeurs négatives, elle leur applique une pente faible mais non nulle, déterminée par un petit coefficient positif. Cela permet de préserver un gradient dans la zone négative et de favoriser un apprentissage plus stable. Sa définition mathématique est la suivante :

$$\text{Leaky ReLU}(z) = \begin{cases} 0.01 z & \text{si } z < 0 \\ z & \text{ailleurs} \end{cases} \quad (2.4)$$


- **Fonction Softmax** : cette fonction d'activation est couramment utilisée dans les réseaux de neurones pour transformer un vecteur de scores en une distribution de probabilités sur un ensemble de classes. Elle est généralement placée en sortie des réseaux convolutifs lors de la classification multi-classes. La fonction Softmax prend en entrée un vecteur de valeurs réelles z et génère un vecteur de probabilités normalisées, dont la somme est égale à 1. Chaque probabilité est comprise entre 0 et 1, et la classe associée à la probabilité la plus élevée est retenue comme prédiction. Elle est définie mathématiquement par l'équation suivante [11] :

$$\text{Softmax}(z_i) = \frac{e^{z_i}}{\sum_{j=1}^k e^{z_j}} \quad (2.5)$$

Où :

- z_i : la valeur associée à la classe i (par exemple, un score produit par un neurone).
- e^{z_i} : on applique la fonction exponentielle à ce score. Cela rend les scores plus distincts (plus grands ou plus petits).
- $\sum_{j=1}^k e^{z_j}$: la somme des exponentielles de tous les scores, utilisée comme facteur de normalisation.
- k : c'est le nombre total de classes.

La figure 2.6 suivante présente les courbes représentatives des quatre fonctions d'activation étudiées précédemment : Sigmoid, Tanh, ReLU, Leaky ReLU et Softmax.



Softmax Function




Figure 2.6. Les courbes des fonctions d'activation.

5.1.3 Couche de pooling

Les couches de pooling, également appelées couches de sous-échantillonnage, sont utilisées dans les réseaux neuronaux convolutifs pour réduire la dimension des cartes de caractéristiques tout en préservant les informations essentielles. Elles permettent de réduire la complexité du modèle en diminuant le nombre de paramètres, ce qui contribue à limiter le risque de surapprentissage et à accélérer l'entraînement. Le pooling vise à conserver uniquement les éléments les plus significatifs des données d'entrée. [13]

On distingue principalement deux types de pooling [13] :

- **Max-Pooling** : Cette technique consiste à diviser la carte de caractéristiques en petites zones distinctes (généralement de taille 2×2) et à retenir la valeur maximale de chaque zone. Elle permet de préserver les informations les plus significatives tout en diminuant la dimension des données.
- **Average-Pooling** : À la différence du max-pooling, cette technique calcule la moyenne des valeurs contenues dans chaque sous-région. Elle offre une réduction plus douce des données, mais peut entraîner une perte de précision dans les détails fins de l'image.




Figure 2.7. Types de pooling

5.1.4 Couches entièrement connectées

Les couches entièrement connectées (ou Fully connected layers) sont généralement situées à la fin d'un réseau convolutif et jouent le rôle de classificateur des caractéristiques extraites par les couches précédentes. Elles permettent un raisonnement de haut niveau en combinant ces caractéristiques pour effectuer la classification finale. Ces couches utilisent souvent la fonction d'activation Softmax, qui transforme les sorties en probabilités comprises entre 0 et 1, facilitant ainsi la prise de décision sur les classes. Ces couches fonctionnent selon plusieurs principes, notamment [13] :

- *Connexion complète* : Dans ces couches, chaque neurone est relié à tous les neurones de la couche précédente. Cette architecture permet de combiner les différentes caractéristiques extraites pour construire une représentation globale de l'image.
- *Processus de classification* : Les couches entièrement connectées prennent en entrée les caractéristiques apprises et produisent les résultats finaux. Par exemple, dans une tâche de classification d'images, elles génèrent un vecteur de probabilités correspondant aux différentes classes possibles.
- *Fonctions d'activation* : Afin de doter le réseau de la capacité d'apprendre des relations complexes et non linéaires, et de réaliser la tâche de classification, les couches utilisent fréquemment des fonctions d'activation. Pour les problèmes de classification multi-classe, la fonction softmax est couramment employée. Elle normalise les scores obtenus en probabilités allant de 0 à 1, simplifiant l'interprétation des prédictions. Dans le contexte de la classification binaire, la fonction sigmoïde est fréquemment choisie, car elle convertit les sorties en probabilités indiquant la probabilité d'appartenance à la classe positive.
- *Ajustement des poids* : Pendant la phase d'entraînement, les poids des connexions sont ajustés afin de minimiser l'erreur entre les prédictions et les étiquettes réelles. Ces couches entièrement connectées sont essentielles pour que le modèle puisse généraliser correctement et fournir des prédictions fiables sur des données nouvelles.




Figure 2.8. Couche entièrement connectée

5.1.5 Couche de Dropout

La couche de dropout est une technique de régularisation utilisée durant l'entraînement d'un réseau neuronal. À chaque itération, un certain pourcentage de neurones (généralement entre 20 % et 50 %) est désactivé de manière aléatoire. Cette désactivation temporaire empêche le réseau de devenir trop

dépendant de certains neurones spécifiques, favorisant ainsi une meilleure généralisation et réduisant le risque de surapprentissage [13].




Figure 2.9. Réseau avant et après régularisation par Dropout

5.1.6 Couches de normalisation par lot

La normalisation par lot (Batch Normalization) est une technique courante en apprentissage profond, utilisée pour rendre l'entraînement des réseaux de neurones plus rapide et plus stable. Elle est généralement insérée entre une couche de convolution et la fonction d'activation. Cette méthode consiste à normaliser les activations d'un mini-lot en ajustant leur moyenne et leur écart type. En agissant localement sur chaque mini-lot, elle limite les variations de distribution des données au cours de l'entraînement, ce qui facilite la convergence du modèle. Elle permet également de réduire le nombre d'époques nécessaires pour atteindre de bonnes performances. Enfin, la Batch Normalization peut être utilisée en complément d'autres techniques, comme le dropout, pour améliorer la précision du modèle, limiter le sur-apprentissage et renforcer la robustesse face aux variations d'initialisation des poids [11].

6. Fonction de perte

La fonction de perte, aussi appelée fonction de coût, évalue l'écart entre les sorties prédites par le modèle et les valeurs réelles attendues. Elle constitue un repère fondamental pour estimer les performances du modèle durant l'apprentissage. En classification, le choix de cette fonction dépend du type de problème : la binary cross-entropy est généralement utilisée pour des classifications binaires, tandis que la categorical cross-entropy est plus appropriée dans les cas de classification multi-classe. Ces fonctions fournissent une indication essentielle permettant de corriger les erreurs du modèle en ajustant ses paramètres afin de minimiser cette perte au cours de l'entraînement [14].

7. Algorithmes d'optimisation

Un optimiseur est fondamental pour l'apprentissage profond, car il est responsable de la mise à jour des poids du modèle dans le but de réduire la perte. Les optimiseurs suivants sont parmi les plus importants [14] :

- Le *SGD (Stochastic Gradient Descent)* met à jour les poids après chaque donnée d'entraînement, mais cette approche peut être instable. L'utilisation de mini-lots permet de stabiliser l'entraînement.
- Le *SGDM avec Momentum* améliore le SGD en ajoutant une inertie basée sur les gradients passés, ce qui aide à converger plus rapidement et à réduire les oscillations.
- Le *NAG (Nesterov Accelerated Gradient)* est une extension de la méthode du momentum, qui estime le gradient à une position future anticipée dans la direction du mouvement. Cette approche permet souvent d'accélérer la convergence tout en améliorant la précision de l'optimisation.
- L'*AdaGrad (Adaptive Gradient Algorithm)* adapte le taux d'apprentissage de chaque paramètre en fonction de son historique de gradients, mais son taux d'apprentissage peut devenir trop petit pour les réseaux complexes.
- Le *RMSProp (Root Mean Square Propagation)* est une modification d'AdaGrad qui utilise une moyenne mobile des gradients, ce qui le rend plus adapté à l'entraînement de réseaux profonds.
- L'*ADAM (Adaptive Moment Estimation)* combine les avantages du Momentum et de RMSProp en adaptant dynamiquement le taux d'apprentissage pour chaque paramètre. Sa simplicité et son efficacité en font un choix très populaire.

8. Les Hyperparamètres en Apprentissage Profond

En apprentissage profond, le choix et la configuration minutieuse d'hyperparamètres clés sont essentiels avant l'entraînement d'un modèle. Ces paramètres ont un impact direct sur l'optimisation de sa performance et l'obtention de résultats optimaux. Ils influencent la dynamique d'apprentissage et la convergence du réseau. Parmi ces hyperparamètres, on retrouve [11] :

- Le *taux d'apprentissage (learning rate)* : contrôle la vitesse à laquelle les poids du modèle sont ajustés au cours de l'entraînement. Un taux trop élevé peut conduire à une convergence rapide, mais au prix d'une instabilité, tandis qu'un taux trop faible peut entraîner un apprentissage trop lent.

- *Le nombre d'époques (epochs)* : Il représente le nombre de passages complets du modèle sur l'ensemble des données d'entraînement. Un nombre insuffisant peut mener à un sous-apprentissage, tandis qu'un nombre excessif peut provoquer un surapprentissage.
- *La taille du mini-lot (mini batch size)* : Elle indique le nombre d'échantillons utilisés pour chaque mise à jour des poids. Une taille réduite peut entraîner une instabilité, tandis qu'une taille importante peut ralentir la convergence.
- *Le nombre de couches et la taille du réseau* : La profondeur et la structure du modèle ont une influence significative sur sa performance. Une architecture trop simple peut résulter en un sous-apprentissage, alors qu'une architecture trop complexe peut causer un surapprentissage.
- *Le choix de la fonction de coût* : La sélection appropriée de cette fonction est cruciale pour la capacité de généralisation du modèle.
- *Le choix de l'algorithme d'optimisation* : Il spécifie la méthode utilisée pour ajuster les poids du modèle.

Dans la section suivante, nous explorerons les architectures de classification les plus répandues dans la littérature.

9. Apprentissage par transfert

L'apprentissage par transfert, ou Transfer Learning, est une méthode puissante en apprentissage automatique qui permet de réutiliser un modèle préalablement développé pour une tâche spécifique afin de faciliter la création d'un nouveau modèle destiné à un scénario différent. Elle se révèle particulièrement avantageuse dans les situations où les données sont rares ou lorsque les ressources en temps et en calcul sont limitées. En réutilisant les connaissances acquises lors de l'apprentissage d'une tâche source, il devient possible de les transférer et ajuster à un nouveau contexte, même si les données disponibles sont insuffisantes pour entraîner un modèle à partir de zéro. Cette méthode s'inspire du fonctionnement du cerveau humain, où des compétences acquises dans un domaine facilitent l'apprentissage dans un domaine connexe, permettant ainsi d'accélérer le développement de modèles et d'améliorer leur performance sans repartir de zéro [15].

En apprentissage profond, où l'entraînement des réseaux nécessite de grandes quantités de données et de puissance de calcul, le transfert d'apprentissage offre une solution efficace. Il repose sur la réutilisation d'un modèle pré-entraîné, tel qu'un réseau formé sur ImageNet, en conservant les couches d'extraction de caractéristiques et en adaptant les couches finales à une nouvelle tâche. Cette approche réduit le temps d'entraînement et améliore les performances, même avec peu de données.

Ce processus est illustré dans la figure suivante à travers un réseau de neurones convolutif : le modèle est d'abord entraîné sur un ensemble de données annotées lié à une tâche source. Ensuite, les paramètres de la partie dédiée à l'extraction des caractéristiques sont réutilisés pour résoudre une nouvelle tâche cible [15].

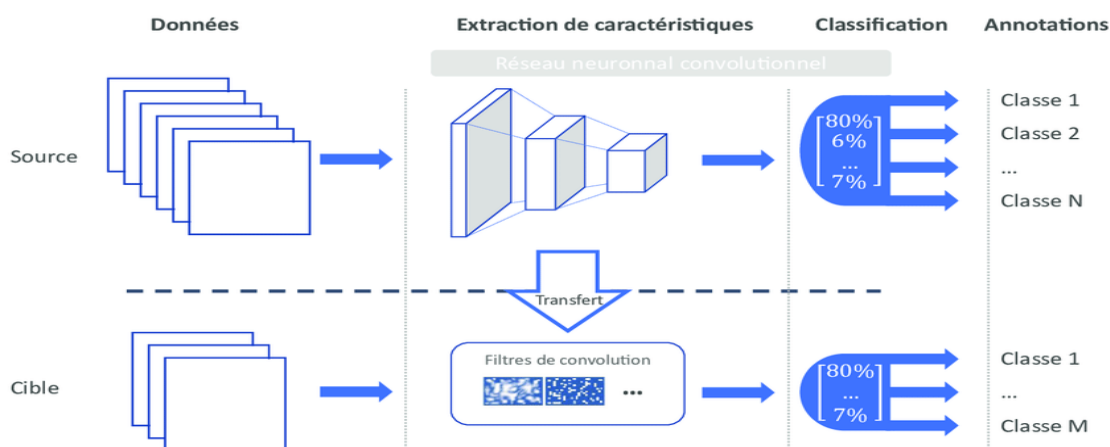


Figure 2.10. Exemple d'apprentissage par transfert utilisant un réseau de neurones convolutif.

10. Architectures de classification les plus connues

L'apprentissage profond s'est récemment distingué par ses performances dans la classification d'images médicales, offrant des résultats souvent supérieurs aux approches classiques. Cette section explore les architectures les plus couramment utilisées dans ce contexte.

10.1 Architecture ResNet50

En 2016, He et al. ont présenté un réseau neuronal convolutif appelé ResNet (Deep Residual Networks), basé sur le concept de bloc résiduel, afin de résoudre le problème de dégradation du gradient, fréquemment rencontré dans les réseaux profonds [16].

Ce problème survient lorsque la précision du réseau atteint un point de saturation, puis diminue rapidement en raison de la perte progressive des gradients lors de la rétropropagation. Pour surmonter cette limitation, les auteurs de l'architecture ResNet ont introduit des blocs résiduels, qui établissent des connexions directes (ou skip connections) entre la sortie d'une couche précédente et l'entrée d'une couche ultérieure. ResNet-50 est l'une des variantes les plus largement utilisées de cette architecture [16].

Le modèle ResNet-50 s'est imposé comme une référence dans le domaine de la classification d'images, reconnu pour sa capacité à traiter efficacement de grands ensembles de données tout en maintenant des performances remarquables. Son innovation majeure réside dans l'intégration de

connexions résiduelles. Ces connexions permettent au réseau d'apprendre des fonctions résiduelles, facilitant ainsi l'entraînement de réseaux très profonds sans être perturbé par les problèmes de disparition du gradient [17].

L'architecture de ResNet-50 peut être divisée en quatre composants principaux :

- *Couches de convolution* : Ces couches initiales sont responsables de l'extraction des caractéristiques fondamentales de l'image d'entrée, telles que les contours, les textures et les formes. Elles sont systématiquement suivies d'une normalisation par lots (*batch normalization*), d'une fonction d'activation ReLU et d'une opération de max pooling. Le max pooling a pour but de réduire les dimensions spatiales de la représentation tout en conservant les informations les plus pertinentes [17].
- *Bloc d'identité (Identity Block)* : Ce bloc a la particularité de propager l'entrée à travers une série de couches de convolution, puis d'ajouter cette entrée au résultat des convolutions. Cette technique permet au réseau d'apprendre des fonctions résiduelles, ce qui contribue significativement à améliorer sa capacité de généralisation [17].
- *Bloc de convolution (Convolutional Block)*: Similaire au bloc d'identité, ce bloc introduit une couche de convolution 1x1. Cette couche permet de réduire le nombre de filtres avant l'application d'une convolution 3x3 [17].
- *Couches entièrement connectées (Fully Connected Layers)* : Ces couches constituent la dernière étape du processus et réalisent la classification finale. La sortie de ces couches est ensuite traitée par une fonction d'activation softmax, qui génère les probabilités d'appartenance de l'image à chaque classe possible.

Grâce à cette architecture ingénieusement conçue, ResNet-50 est capable de construire des réseaux d'une profondeur considérable tout en surmontant efficacement les problèmes de disparition du gradient. Cette caractéristique en fait un choix privilégié pour de nombreuses tâches de classification d'images [17].

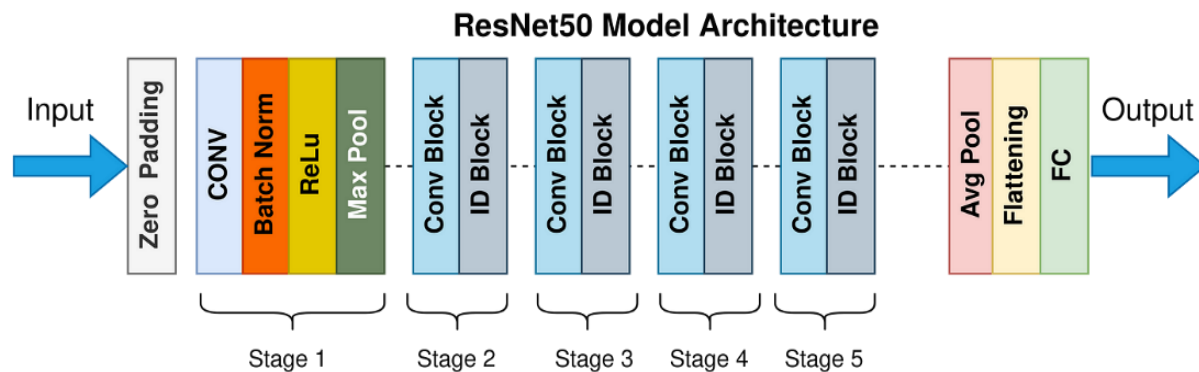


Figure 2.11. Architectures ResNet50

10.2 Architecture DenseNet121

DenseNet est un réseau neuronal convolutif dont la particularité réside dans l'utilisation de connexions denses entre ses différentes couches. Contrairement à un réseau convolutionnel traditionnel, chaque couche au sein d'un bloc dense de DenseNet reçoit en entrée non seulement la sortie de la couche précédente, mais également les sorties de toutes les couches qui la suivent dans ce même bloc. Cette architecture en blocs denses est illustrée à la Figure 2.12, où chaque bloc dense est interconnecté par une couche de transition. Chaque bloc dense est constitué d'un ensemble de couches convolutives, et chaque couche est connectée à toutes les autres couches appartenant au même bloc. Cette connectivité dense établit un lien direct entre le gradient de la fonction de coût et les entrées initiales, ce qui favorise un flux d'informations plus direct et efficace à travers le réseau. De plus, cette structure contribue à améliorer la régularisation, réduisant ainsi les risques de surapprentissage et de dégradation du gradient [16].

DenseNet-121 est un réseau neuronal convolutif de la famille DenseNet, caractérisé par son architecture dense. Il est composé de 121 couches, organisées en quatre blocs denses, favorisant une connectivité maximale entre les couches. Cette conception facilite l'apprentissage des caractéristiques et améliore la classification. Chaque bloc dense est constitué de couches de convolution imbriquées avec des couches de transition. Ces dernières ont pour rôle de réduire progressivement les dimensions spatiales et le nombre de canaux de la représentation, contribuant ainsi à l'obtention d'une représentation robuste des données d'entrée [18].

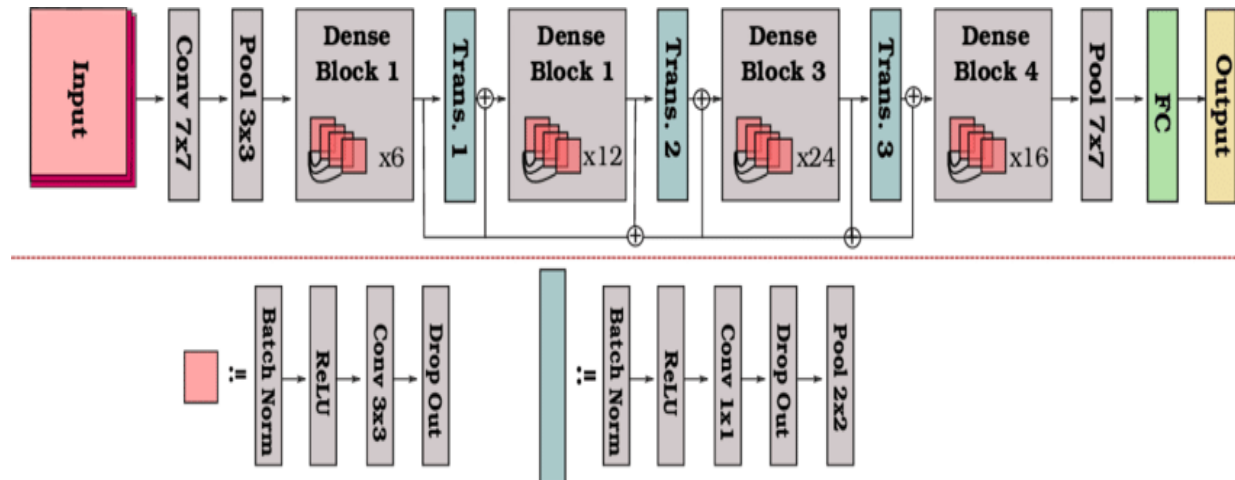


Figure 2.12. Architecture DenseNet121

10.3 Architecture MobileNetV2

MobileNet représente une architecture de réseau neuronal convolusionnel spécifiquement élaborée pour satisfaire les contraintes des systèmes embarqués. Elle repose sur la convolution séparable profonde afin de minimiser la complexité et les besoins en calcul, favorisant ainsi la rapidité et la légèreté. MobileNet peut fonctionner efficacement sur des plateformes embarquées aux ressources limitées et consomme moins d'énergie que d'autres architectures de CNN, ce qui en fait un choix pertinent pour les systèmes embarqués exigeant une faible consommation énergétique [16].

MobileNetV2 introduit un nouveau module basé sur une structure résiduelle inversée, dans lequel l'expansion de la dimension des canaux précède la convolution depthwise, suivie d'une projection linéaire. Cette architecture permet d'obtenir de bonnes performances en reconnaissance d'objets et en segmentation sémantique, tout en restant adaptée aux dispositifs embarqués. Elle débute par une couche convolusionnelle standard avec 32 filtres, suivie de 17 blocs de type inverted residual bottleneck, constituant un total d'environ 53 couches. Pour une image d'entrée de 224×224 pixels, le modèle nécessite environ 300 millions d'opérations de multiplication-addition et comporte environ 3,4 millions de paramètres. La précision du modèle est améliorée en supprimant la fonction d'activation ReLU6 à la sortie de certains blocs, notamment ceux avec une projection linéaire, afin de préserver les informations linéaires essentielles à la représentation des caractéristiques [19]. Cette architecture est illustrée dans la figure 2.13 suivante.




Figure 2.13. Architecture MobileNetV2

10.4 InceptionV3

InceptionV3 est une architecture avancée de réseau de neurones convolutifs développée par Google, appartenant à la famille des modèles Inception. Elle comprend environ 48 couches profondes. Ce modèle est pré-entraîné sur le jeu de données ImageNet, contenant des millions d'images, ce qui lui permet de classer des images dans 1000 catégories d'objets.

Grâce à son architecture modulaire et optimisée, InceptionV3 est capable d'extraire efficacement des caractéristiques même à partir d'images complexes, ce qui en fait un choix pertinent pour de nombreuses applications de vision par ordinateur. Le modèle prend en entrée des images de taille $299 \times 299 \times 3$ (hauteur, largeur, canaux de couleur RGB), et toute image utilisée avec ce modèle doit être redimensionnée à ces dimensions [20]. Cette architecture est illustrée dans la figure suivante 2.14.




Figure 2.14. Architecture InceptionV3

10.5 EfficientNetB0

EfficientNetB0 a surpassé les autres modèles de pointe entraînés sur la base de données ImageNet en utilisant une approche différente de celle des CNN profonds traditionnels, qui ajustent chaque dimension avec un ensemble prédéfini de coefficients d'échelle [21].




Figure 2.15. Architecture EfficientNetB0

Le composant principal d'EfficientNet, hérité initialement de MobileNetV2, est le bloc MBConv (Mobile Inverted Bottleneck Convolution), qui repose sur une structure inverted bottleneck, dans laquelle les canaux sont d'abord étendus puis comprimés. Cependant, en raison de son budget FLOPS (Floating Point Operations per Second) plus élevé, ce bloc est utilisé de manière plus intensive dans EfficientNet que dans MobileNetV2. Des connexions directes (skip connections) sont établies entre les blocs MBConv, notamment entre les couches à faible nombre de canaux, afin de faciliter la propagation des gradients et de réduire la perte d'information. Chaque bloc MBConv comprend une phase d'expansion suivie d'une compression des canaux, dans un ordre inversé par rapport aux blocs classiques. Par ailleurs, les convolutions depthwise separable utilisées dans cette architecture

permettent de réduire considérablement le coût computationnel, presque d'un facteur k^2 , où k est la taille du noyau de convolution 2D (par exemple, 3×3).

11 Métriques d'Évaluation

Les métriques d'évaluation sont des mesures quantitatives utilisées pour évaluer la performance d'un modèle, d'un algorithme ou d'un système, en fonction de critères spécifiques tels que la matrice de confusion, le taux de classification correcte (Accuracy), le rappel, la précision, le F1-Score ou encore la courbe ROC.

11.1 Matrice de confusion

		Classe réelle	
		-	+
Classe prédite	-	True Negatives <i>(vrais négatifs)</i>	False Negatives <i>(faux négatifs)</i>
	+	False Positives <i>(faux positifs)</i>	True Positives <i>(vrais positifs)</i>

Figure 2.16. Matrice de confusion

Cette matrice comporte quatre paramètres, qui sont [11] :

- Vrai positif (VP) : le modèle prédit positif pour une valeur qui est réellement positive.
- Vrai négatif (VN) : le modèle prédit négatif pour une valeur qui est réellement négative.
- Faux positif (FP) : résultat erroné ou le modèle prédit positif alors qu'il est en réalité négatif.
- Faux négatif (FN) : résultat erroné ou le modèle prédit négatif alors qu'il est en réalité positif.

11.2 Taux de Classification Correcte (Accuracy)

Il s'agit du rapport entre le nombre de prédictions correctes (vrais positifs + vrais négatifs) et le nombre total d'instances évaluées [11].

$$\text{Accuracy} = \frac{(\text{VP} + \text{VN})}{(\text{VP} + \text{VN} + \text{FP} + \text{FN})} \quad (2.6)$$

11.3 Rappel (Recall)

Il représente la proportion de prédictions positives correctes par rapport au nombre total de véritables cas positifs [11].

$$\text{Recall} = \frac{\text{VP}}{(\text{VP} + \text{FN})} \quad (2.7)$$

11.4 Précision (Precision)

La précision mesure la proportion de prédictions positives correctes par rapport au nombre total de prédictions positives. Elle évalue la qualité des prédictions positives du modèle [11].

$$\text{Precision} = \frac{VP}{VP+FP} \quad (2.8)$$

11.5 F1-Score

Le F1-score mesure la moyenne harmonique de la précision et du rappel, fournissant une évaluation équilibrée des performances du modèle [11].

$$\text{F1 - Score} = 2 \times \frac{\text{Pr ecision} \times \text{Recall}}{\text{Pr ecision} + \text{Recall}} \quad (2.9)$$

11.6 Courbe ROC et AUC

La courbe ROC (Receiver Operating Characteristic) et l'AUC (Area Under the ROC Curve) sont d'autres paramètres très importants pour évaluer la robustesse d'un modèle. La courbe ROC est obtenue en traçant la sensibilité (TPR, True Positive Rate) en fonction de 1 - spécificité (FPR, False Positive Rate) pour différents seuils de classification. Plus cette courbe se rapproche du coin supérieur gauche, meilleure est la performance du modèle. L'AUC représente la surface sous la courbe ROC et fournit une mesure de la qualité globale de la classification. Elle varie entre 0.5 pour un classifieur aléatoire et 1 pour un classifieur parfait. Un avantage majeur de l'AUC par rapport à d'autres métriques est son insensibilité aux données déséquilibrées, ce qui la rend plus fiable lorsque la taille des classes diffère significativement [11].

Ces différentes métriques permettent d'évaluer de manière approfondie les performances du modèle, en tenant compte non seulement de son exactitude globale, mais aussi de sa capacité à identifier correctement les cas positifs, tout en limitant à la fois les faux positifs et les faux négatifs. Elles contribuent ainsi à garantir que le modèle est à la fois précis, robuste et fiable dans ses prédictions.

12 L'état de l'art

Plusieurs études récentes ont été menées sur la détection et la catégorisation de l'arthrose du genou à partir d'images radiologiques. La plupart de ces techniques s'appuient sur l'emploi de modèles d'apprentissage profond.

- Eskandari et al. (2021) [22] ont développé une méthode visant à accélérer le diagnostic de l'arthrose tout en limitant la subjectivité des jugements cliniques. Cette approche repose sur deux indicateurs essentiels : la réduction de l'espace articulaire (JSN) et la présence d'ostéophytes. Le modèle a été évalué à l'aide d'une validation croisée à trois plis et a atteint une exactitude moyenne de 77,24 %, surpassant plusieurs autres approches de classification fondées sur l'apprentissage profond.

- Abdullah et al. (2022) [23] ont proposé une méthode combinant Faster R-CNN pour la localisation des articulations et un modèle de classification basé sur ResNet-50 et AlexNet, en s'appuyant sur les niveaux de Kellgren-Lawrence. Leur système, évalué sur 3172 radiographies, a atteint une précision de 98,90 %, démontrant une efficacité remarquable pour l'évaluation automatisée de la sévérité de l'arthrose du genou.
- Abdul Sami Mohammed et al. (2023) [24] ont proposé une méthode reposant sur des réseaux de neurones profonds résiduels pour détecter et classer le stade de progression de l'arthrose du genou à partir d'images radiographiques prétraitées. Leur approche a exploité plusieurs architectures de réseaux de neurones convolutifs pré-entraînées, notamment VGG16, VGG19, ResNet101, MobileNetV2, InceptionResNetV2 et DenseNet121. Parmi ces modèles, ResNet101 s'est distingué par ses performances supérieures, atteignant une précision maximale de 89 %.
- Selon Jain et al. (2023) [25], leur approche a consisté à utiliser l'architecture InceptionV3, après avoir également entraîné 14 modèles distincts, dont VGG16, VGG19 et ResNet. Le modèle InceptionV3 a atteint une précision d'entraînement optimale de 91 % et une précision de test de 67 %, permettant ainsi une détection efficace de la présence et du degré d'avancement de l'arthrose.
- Rabbia Mahum et al. (2023) [26] ont introduit une fonction de perte repondérée afin de gérer le déséquilibre des classes, et ont exploité les connexions denses de DenseNet combinées à des techniques de régularisation pour limiter le surapprentissage. Le modèle, entraîné sur le jeu de données Mendeley VI et validé par validation croisée sur le jeu OAI, a obtenu une précision de 98,22 % sur le jeu de test et de 98,08 % en validation croisée, démontrant une grande robustesse et une excellente capacité de généralisation.
- Kumar et al. (2024) [27] ont proposé une approche de transfer learning basée sur la famille EfficientNet. Trois variantes (EfficientNet-B5, B6, B7) ont été évaluées, avec application de techniques d'augmentation pour compenser le déséquilibre des classes. Les optimiseurs Adam et RMSprop ont été utilisés pour améliorer la performance. Le modèle EfficientNet-B7 a obtenu la meilleure précision, atteignant 78,53%, surpassant d'autres architectures telles que CNN et ResNet.
- Alnabi et al. (2025) [28] ont proposé un cadre hybride d'apprentissage profond pour la classification des stades de l'arthrose du genou à partir d'images radiographiques. Ils ont

combiné plusieurs architectures de réseaux neuronaux profonds (EfficientNetB0, EfficientNetV2B0, XceptionNet, ResNetRS101, RegNetY032) avec des stratégies de fusion (caractéristiques, scores, décisions et méta-fusion). Des techniques de prétraitement (CLAHE) et d'augmentation des données (SMOTE) ont également été appliquées. Leur approche a atteint une précision de 90,61 % sur le premier jeu de données et de 70 % sur le second, surpassant les approches existantes.

- Ren et al. (2025) [29] ont développé une méthode d'apprentissage profond nommée OA-MEN, fusionnant les architectures ResNet et MobileNet à l'aide d'une stratégie de fusion multi-échelle des caractéristiques. Cette approche vise à détecter et classifier l'arthrose du genou de manière plus efficace. Le modèle a été évalué sur un ensemble de données jamais vues auparavant, obtenant une précision de 84,88 % et une AUC de 89,11 %, dépassant ainsi les performances des modèles traditionnels.
- Ilkay Cinar (2025) [30] a mené une étude comparative sur l'efficacité des algorithmes de machine learning et de deep learning pour la détection de l'arthrite du genou. L'étude a impliqué plusieurs modèles : k-NN, SVM et GBM pour le machine learning, ainsi que DenseNet, EfficientNet et InceptionV3 pour le deep learning. Des modèles de classification de type YOLOv8 ont également été évalués. L'étude, menée sur un jeu de données annoté de 1650 images réparties en 80 % pour l'apprentissage, 10 % pour la validation et 10 % pour le test. Les modèles YOLOv8 ont surpassé les autres algorithmes, avec le modèle YOLOv8x-cls atteignant une précision de 86,96 %.
- Wang et al. (2025) [31] ont utilisé des autoencodeurs convolutionnels intégrant des mécanismes d'attention pour extraire des caractéristiques significatives. Leur modèle, combinant la méthode de sélection récursive de caractéristiques (RFE) et une approche de Stacking, a obtenu un F1-score de 93,5 % et une AUC de 96,5 %.

13 Conclusion

Ce chapitre a présenté l'intelligence artificielle comme un pilier fondamental dans la détection et la classification de l'arthrose, en soulignant son rôle croissant dans l'analyse des images médicales. Après avoir posé les bases théoriques de l'IA, de l'apprentissage automatique et de l'apprentissage profond, l'accent a été mis sur les réseaux de neurones convolutifs. L'apprentissage par transfert a été exploré à travers plusieurs architectures reconnues, telles que ResNet50, DenseNet121,

Chapitre 2 : Techniques d'apprentissage profond pour la détection de l'arthrose

MobileNetV2, InceptionV3 et EfficientNetB0, qui ont démontré leur efficacité dans la classification d'images médicales. Ces modèles, en particulier les CNN, ont prouvé leur capacité à extraire des caractéristiques pertinentes et à apporter une aide précieuse au diagnostic. Les travaux récents confirment non seulement leurs performances, mais aussi leur potentiel à transformer les pratiques médicales en facilitant un diagnostic plus rapide et une prise en charge précoce. Dans un contexte de recherche en constante évolution, l'intégration du deep learning dans les systèmes de santé s'impose comme un levier majeur d'innovation, susceptible d'améliorer significativement la qualité de vie des patients atteints d'arthrose.

Chapitre 3 : Classification Automatique de l'Arthrose du Genou : Méthodes et Résultats

1. Introduction

L'arthrose du genou est une pathologie articulaire chronique fréquente, caractérisée par une dégradation progressive du cartilage. Son évaluation radiographique repose généralement sur la classification de Kellgren-Lawrence (KL), répartie en cinq grades de sévérité. L'apprentissage profond offre aujourd'hui des perspectives prometteuses pour automatiser cette classification à partir de radiographies, améliorant ainsi la rapidité et la fiabilité du diagnostic.

Cependant, cette tâche est confrontée à un défi majeur : le déséquilibre des classes, particulièrement fréquent dans les données médicales. Pour y remédier, il est essentiel de mettre en œuvre des techniques de prétraitement appropriées, telles que l'augmentation de données ou l'équilibrage par échantillonnage, afin d'assurer une représentation équitable des différentes classes et d'améliorer la performance des modèles.

Dans ce chapitre, nous présentons nos contributions pour améliorer la classification automatique des stades de l'arthrose du genou à partir d'images radiographiques, en mettant l'accent sur la gestion du déséquilibre des données. Ce travail est structuré en cinq parties, implémentés en Python :

1. *Méthode proposée* : Cette section présente notre approche méthodologique, structurée en trois étapes principales : le prétraitement des données (incluant la normalisation, l'équilibrage des classes et l'augmentation par transformations géométriques), la classification, puis l'explicabilité du modèle.
2. *Optimisation de la classification de l'arthrose du genou sur la base Knee Osteoarthritis* : Nous y explorons l'évaluation comparative de la classification en 5 classes, l'expérimentation avec un équilibrage partiel des données, la reconfiguration de la classification en 4 classes, et une analyse comparative des différentes configurations. Une comparaison de nos résultats avec l'état de l'art est également présentée.
3. *Validation sur le jeu de données annoté pour la détection de l'arthrose du genou (Annotated Dataset for Knee Arthritis Detection)* : Dans cette partie, nous présentons les résultats obtenus après l'application des modèles pré-entraînés sur une seconde base de données, suivie d'une analyse comparative avec l'état de l'art.
4. *Analyse de l'explicabilité des modèles* : Nous explorons la transparence et l'interprétabilité des modèles à l'aide de l'outil LIME, pour mieux comprendre leurs décisions.
5. *Développement d'une interface graphique interactive* : Nous présentons l'interface graphique interactive conçue pour faciliter l'utilisation du modèle par les professionnels de santé.

2. Environnement de développement et outils d'implémentation

2.1 Python

Python est un langage de programmation open source, multiplateforme, orienté objet et de haut niveau. Il est largement utilisé dans divers domaines tels que le développement logiciel, l'analyse de données et, plus particulièrement dans l'intelligence artificielle et l'apprentissage profond. En tant que langage interprété, Python permet l'exécution du code sans compilation préalable, ce qui le rend particulièrement accessible aussi bien aux débutants qu'aux utilisateurs expérimentés. Il est notamment très prisé dans les domaines de l'apprentissage profond et de la science des données, contribuant de manière significative à l'essor du big data grâce à ses vastes bibliothèques standards disponibles gratuitement [32], parmi les plus utilisées :

1. TensorFlow : est une bibliothèque open source développée par Google, initialement conçue pour les calculs numériques à grande échelle. Elle s'est imposée comme un outil de référence dans le domaine de l'apprentissage profond, tout en prenant en charge des algorithmes classiques d'apprentissage automatique, ce qui en fait un outil polyvalent pour la recherche et le développement en intelligence artificielle [33].
2. Keras : est une interface de programmation d'application (API) de haut niveau pour l'apprentissage profond, également développée par Google. Conçue pour simplifier la création, l'entraînement et l'évaluation de réseaux de neurones. Keras prend en charge plusieurs backends de calcul (notamment TensorFlow), ce qui la rend à la fois puissante, modulaire et facile à utiliser [34].

2.2 Kaggle

Kaggle est une plateforme communautaire en ligne destinée à la science des données et à l'intelligence artificielle. Elle fournit également un accès gratuit à des processeurs graphiques haute performance, tels que la NVIDIA Tesla P100 ou la Tesla T4, ce qui en fait un outil idéal pour l'entraînement de modèles d'apprentissage profond. En plus de ses ressources matérielles, la plateforme propose un large éventail de jeux de données, de notebooks partagés, de compétitions en IA, et une communauté active de chercheurs et praticiens. Cela en fait un espace d'échange, d'apprentissage et de collaboration très apprécié dans le domaine d'intelligence artificielle [35].

3. Description des bases de données

Pour entraîner et évaluer les performances des modèles de classification de l'arthrose du genou, deux jeux de données radiographiques publics ont été utilisés qui sont :

3.1 Jeu de données : Knee Osteoarthritis Dataset with KL Grading–2018 (KOD-KL-2018)

La base de données *KOD-KL-2018* contient 5778 images radiographiques du genou, conçues pour faciliter la détection et l'évaluation de l'arthrose à l'aide de techniques d'intelligence artificielle. Chaque image est annotée par des experts selon le système de classification de Kellgren-Lawrence (KL), qui permet d'évaluer le degré de gravité de l'arthrose, répartie en cinq grades distincts [36].

Le tableau 3.1 suivant présente un résumé des cinq grades et la répartition des images par classe:

Grade	Critères cliniques	Nombre d'images
KL0	Genou sain	2286
KL1	Rétrécissement artriculaire douteux	1046
KL2	Ostéophytes avec léger rétrécissement artriculaire	1516
KL3	Ostéophytes multiples avec rétrécissement marqué	757
KL4	Lésions sévères avec déformation de l'articulation	173

Tableau 3.1: Classification de la base de données KOD-KL-2018.

La figure 3.1 suivante présente des exemples d'images issues de cette base de données, illustrant les cinq grades de classification de l'arthrose du genou à partir d'images radiographiques.



Figure 3.1. Exemples d'images issues de la base de données KOD-KL-2018.

3.2 Jeu de données: Annotated Dataset for Knee Arthritis Detection (AD-KAD)

La base de données AD-KAD comprend 1650 images radiographiques du genou annotées par des experts. Ces images sont classées selon cinq grades de sévérité : normal, douteux, léger, modéré et sévère. Cette classification vise à faciliter la détection et l'évaluation des stades de l'arthrose [37].

La classification en cinq grades, présentée dans le tableau suivant, permet d'évaluer la sévérité de l'arthrose du genou à partir d'images radiographiques.

La répartition des images selon les cinq grades, ainsi que la description associée à chaque niveau de sévérité, sont présentées dans le tableau 3.2 suivant :

Grade	Critères cliniques	Nombre d'images
Normal	Absence de symptômes et de signes radiologiques	514
Douteux	Symptômes légers, signes radiologiques incertains	477
Léger	Douleur légère, légère réduction de l'espace articulaire	232
Modéré	Douleur modérée, signes radiologiques clairs	221
Sévère	Douleur intense, déformation articulaire, réduction importante de l'espace articulaire	206

Tableau 3.2. Classification de la base de données AD-KAD.

La figure 3.2 suivante montre des exemples d'images extraites de cette base de données, illustrant les cinq grades de classification de l'arthrose du genou à partir d'images radiographiques.



Figure 3.2. Exemples d'images issues de la base de données AD-KAD.

4. Méthodes proposées

Cette section constitue le cœur de notre étude, présentant une méthodologie rigoureuse structurée en trois phases complémentaires. Notre objectif est de développer un système de classification de l'arthrose du genou à la fois robuste, précis et interprétable.

A. Phase de prétraitement : La qualité des données étant primordiale pour la performance des modèles, nous avons entamé notre démarche par un *prétraitement rigoureux*. Celui-ci comprend l'*équilibrage des classes*, indispensable pour corriger la distribution déséquilibrée des grades de sévérité, ainsi que l'*augmentation des données* via des transformations géométriques. Ces étapes permettent d'enrichir le jeu de données d'apprentissage, tout en

améliorant la capacité de généralisation et la résilience des modèles face à la variabilité des images radiographiques.

B. Phase de classification par apprentissage profond : La classification des images radiographiques du genou est assurée grâce à l'exploitation de plusieurs architectures de réseaux de neurones profonds pré-entraînés, reconnues par leurs performances en vision par ordinateur, notamment : DenseNet121, ResNet50, MobileNetV2, InceptionV3 et EfficientNetB0. Ces modèles permettent d'extraire automatiquement les caractéristiques discriminantes à partir des images, facilitant la séparation entre les différents stades.

C. Phase d'explicabilité des modèles : Afin de pallier l'effet *boîte noire* associé aux modèles d'apprentissage profond, une phase d'explicabilité a été intégrée. Nous avons utilisé la technique *LIME (Local Interpretable Model-agnostic Explanations)*, qui met en évidence les régions de l'image ayant influencé la décision du modèle. Cette analyse visuelle permet de mieux comprendre le raisonnement algorithmique, en rendant le processus décisionnel plus transparent et interprétable par les professionnels de santé.

L'organigramme ci-dessous (figure 3.3) illustre les étapes, mettant de notre projet.



Figure 3.3. Organigramme général de notre méthode de classification de l'arthrose

4.1 Prétraitement des données

La qualité des données constitue un facteur déterminant dans les performances d'un modèle de deep learning, ce qui rend le prétraitement indispensable pour assurer la fiabilité des résultats. Ce processus s'articule autour de plusieurs étapes successives, allant du chargement initial des données jusqu'à leur équilibrage et augmentation, dans le but d'obtenir un jeu de données propre, équilibré et optimisé pour l'apprentissage.

4.1.1 Normalisation de données

Les images sont d'abord redimensionnées pour correspondre aux dimensions d'entrée requises par les modèles de classification. Ensuite, nous procédons à une normalisation des valeurs de pixels, en convertissant les intensités initialement comprises entre 0 et 255 vers une échelle standardisée de 0 à 1. Cette transformation permet d'homogénéiser les données, de limiter l'influence des grandes valeurs numériques, et favorise une convergence plus rapide et plus stable lors de l'entraînement du réseau neuronal.

La figure 3.4 suivante présente un exemple comparatif des images avant et après l'étape de normalisation.

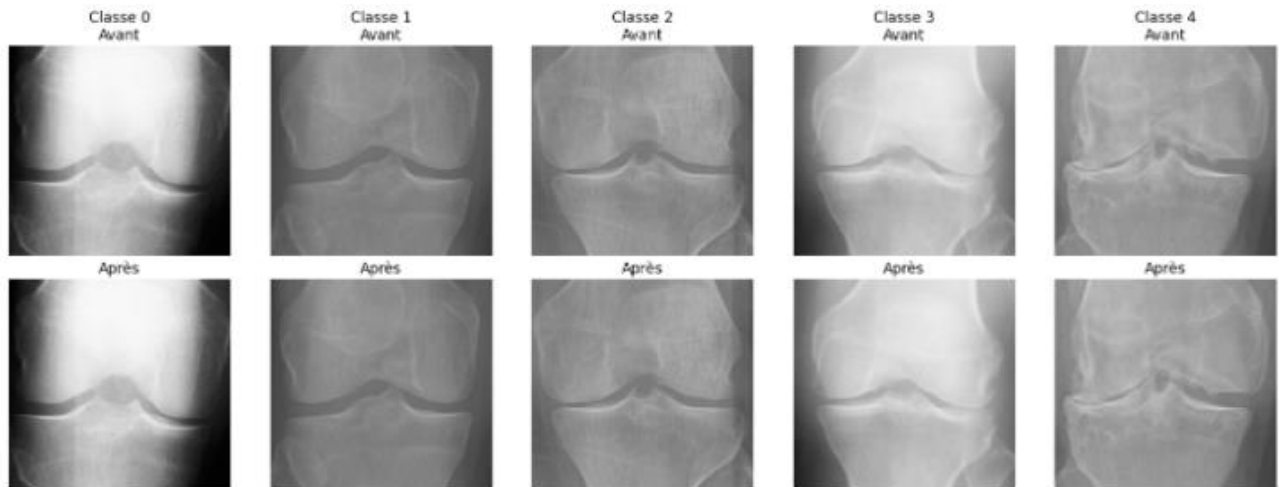


Figure 3.4. Illustration des images radiographiques avant et après l'étape de normalisation

4.1.2 Équilibrage des classes

L'analyse des données a révélé un déséquilibre important dans la répartition des grades de sévérité de l'arthrose dans les bases originales, avec une surreprésentation des classes 0 et 1, et une sous-représentation des classes 3 et 4. Cette asymétrie peut compromettre la capacité de généralisation du modèle, en le poussant à favoriser les classes majoritaires au détriment des formes plus sévères, moins fréquentes.

Pour limiter ce biais d'apprentissage, nous avons appliqué une technique de sur-échantillonnage (oversampling), consistant à dupliquer les exemples des classes minoritaires. Cette approche permet de rééquilibrer la distribution des données et d'assurer au modèle un apprentissage plus équitable, en lui offrant une exposition suffisante à chaque niveau de sévérité.

Ainsi, la détection des cas avancés d'arthrose devient plus fiable, améliorant la justesse globale des prédictions.

Les figures 3.5 et 3.6 suivantes illustrent une comparaison de la distribution des classes avant et après l'étape d'équilibrage pour les deux bases de données.

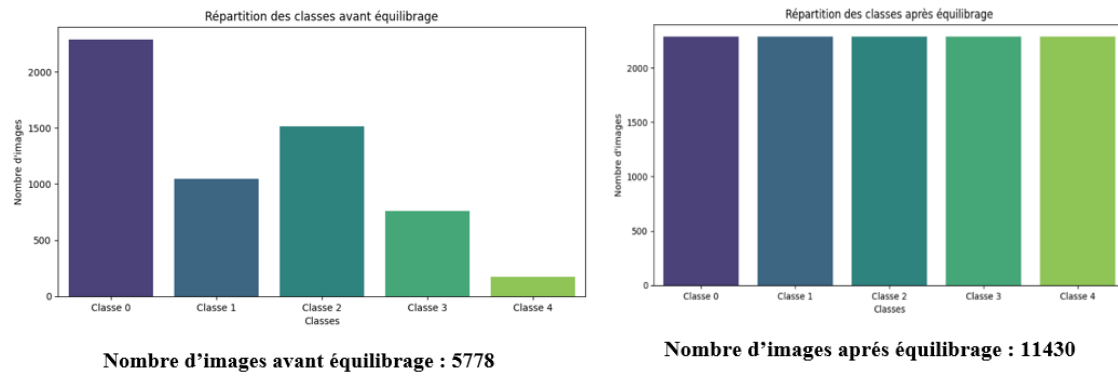


Figure 3.5. Répartition des classes dans la base de données KOD-KL-2018 avant et après l'étape d'équilibrage.

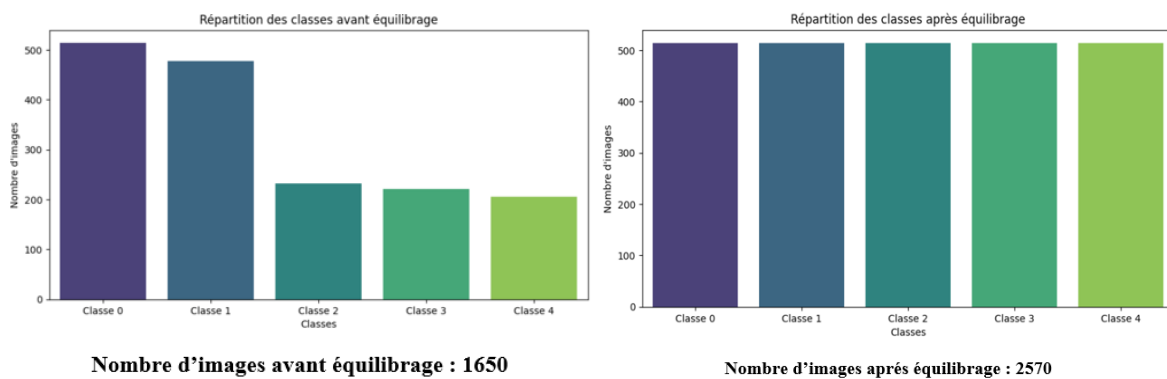


Figure 3.6. Répartition des classes dans la base de données AD-KAD avant et après l'étape d'équilibrage.

Après les étapes de prétraitement, les données sont divisées en trois sous-ensembles distincts : 70 % pour l'entraînement, 15% pour la validation et 15% pour le test. Cette répartition vise à assurer un apprentissage efficace, une évaluation continue des performances pendant l'entraînement, ainsi qu'une estimation fiable de la capacité de généralisation du modèle sur des données non vues.

4.1.3 Augmentation de données

Pour renforcer la capacité de généralisation et de réduire le risque de surapprentissage, nous avons mis en œuvre des techniques d'augmentation de données reposant sur des transformations géométriques stochastiques. Ces transformations comprennent des rotations (jusqu'à $\pm 20^\circ$), des zooms (jusqu'à 20 %), des retournements horizontaux et verticaux, ainsi qu'un cisaillement de 10%.

Ces opérations sont exclusivement appliquées aux images d'entraînement, afin de générer des variantes réalistes et d'accroître la diversité du jeu de données. Cette approche contribue à

améliorer la robustesse du modèle face à la variabilité interindividuelle, aux conditions cliniques hétérogènes et aux perturbations visuelles, tout en optimisant ses performances sur des données non vues.

La figure 3.7 suivante montre des exemples d'images après l'application de diverses transformations géométriques.

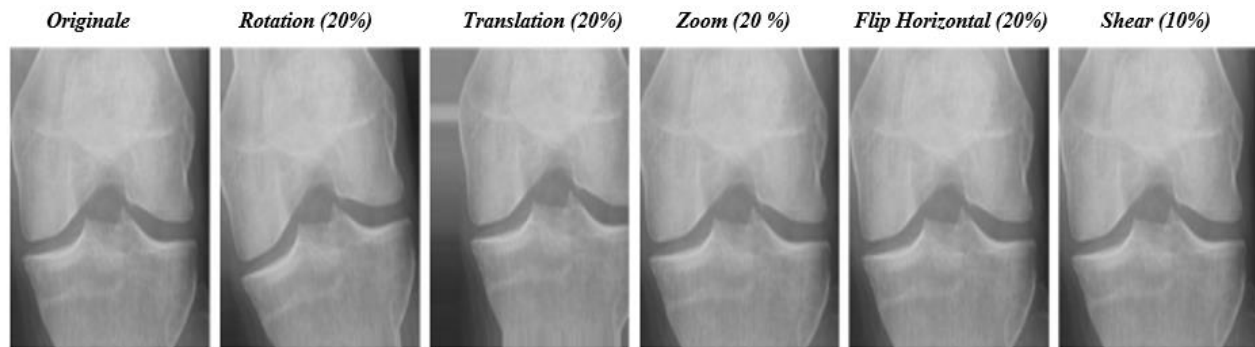


Figure 3.7. Exemples d'images après application de transformations géométriques.

4.2 Classification des stades de l'arthrose

Cette section se concentre sur l'évaluation de diverses architectures de réseaux de neurones convolutifs pré-entraînés bien établies à savoir DenseNet121, ResNet50, EfficientNetB0, InceptionV3 et MobileNetV2. Ces modèles, réputés pour leur efficacité en vision par ordinateur, ont été choisis pour leur potentiel à classifier les différents grades de sévérité de l'arthrose à partir d'images radiographiques du genou.

Pour garantir une évaluation impartiale et systématique, un environnement de test unifié a été mis en place pour toutes les architectures. Cette standardisation nous a permis de comparer leurs performances avec précision et de tirer parti de leur capacité à extraire automatiquement des caractéristiques hautement discriminantes, indispensables à la classification d'images médicales.

4.2.1 Notre DenseNet121 adapté pour la Classification de l'Arthrose

Dans cette étude, nous avons exploité le modèle DenseNet121 pré-entraîné sur ImageNet. Afin de l'adapter à la classification des grades de sévérité de l'arthrose, la couche de classification d'origine a été supprimée. Cette modification permet de conserver les représentations apprises sur un vaste corpus d'images tout en spécialisant le modèle à notre domaine d'application. Pour équilibrer généralisation et spécialisation, les couches profondes du réseau ont été partiellement réentraînées : les 50 dernières couches ont été dégelées pour permettre un affinement (fine-tuning) des paramètres sur notre jeu de données, tandis que le reste du réseau est resté figé. À la sortie du bloc convolutionnel, nous avons intégré une couche GlobalAveragePooling2D qui réduit chaque

carte de caractéristiques en une seule valeur, permettant ainsi une réduction efficace de la dimensionnalité tout en préservant les informations essentielles. Cette représentation condensée est ensuite transmise à une séquence de trois couches entièrement connectées comprenant respectivement 512, 256 et 128 neurones, activées par la fonction ReLU. Pour renforcer la robustesse du modèle et prévenir le surapprentissage, des couches de dropout avec des taux décroissants (0.4, 0.3 et 0.2) ont été insérées après chaque couche dense. Enfin, une couche de sortie dense avec une activation softmax permet de produire une probabilité d'appartenance pour chaque classe de sévérité de l'arthrose, facilitant ainsi une classification multi-classes fiable et interprétable.

La figure 3.8 suivante illustre l'architecture de DenseNet121 que nous avons personnalisée pour la classification de l'arthrose.




Figure 3.8. Notre architecture personnalisée de DenseNet121.

4.2.2 Notre Resnet50 adapté pour la Classification de l'Arthrose

Nous avons également tiré parti du modèle ResNet50 pré-entraîné, reconnu pour sa profondeur maîtrisée et ses blocs résiduels, qui facilitent la propagation du gradient et améliorent la stabilité de l'apprentissage. Afin d'adapter cette architecture à notre tâche, la couche de classification d'origine a été supprimée. Aussi, seules les 50 dernières couches du réseau ont été rendues entraînaibles, permettant un fine-tuning ciblé tout en préservant les paramètres généraux appris lors de le pré-entraînement. À la sortie du bloc convolutionnel principal, nous avons intégré une couche GlobalAveragePooling2D, qui condense les cartes de caractéristiques en un vecteur compact, sans perte d'information critique. Ce vecteur est ensuite traité par une chaîne de trois couches denses de 512, 256 et 128 neurones, activées par la fonction ReLU. Pour limiter le surapprentissage, des couches de dropout avec des taux décroissants (0.4, 0.3 et 0.2) ont été

insérées après chaque couche dense. Enfin, une couche de sortie avec activation softmax assure la prédiction des probabilités d'appartenance aux différents grades de sévérité de l'arthrose.

La figure 3.9 suivante illustre l'architecture de ResNet50 que nous avons personnalisée pour la classification de l'arthrose.

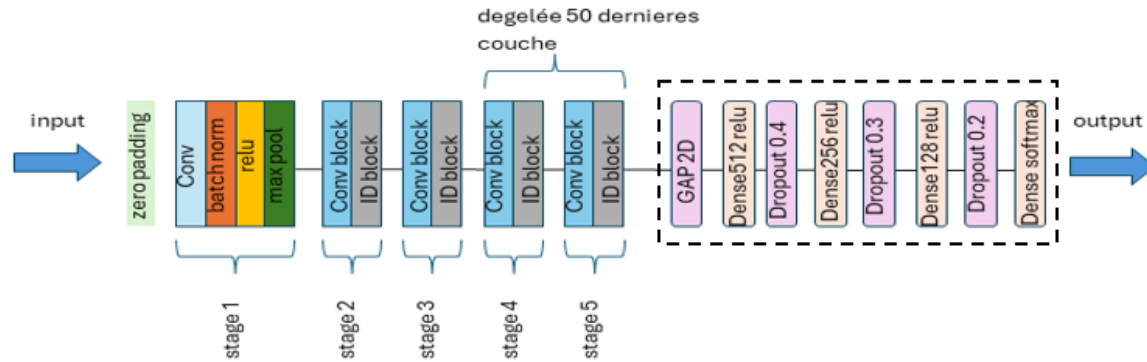


Figure 3.9. Notre architecture personnalisée de ResNet50.

4.2.3 Notre Efficientnetb0 adapté pour la Classification de l'Arthrose

L'architecture EfficientNetB0 se distingue par son approche novatrice d'optimisation conjointe de la profondeur, de la largeur et de la résolution. Cette stratégie lui permet d'atteindre un excellent compromis entre la précision et l'efficacité computationnelle, et ce, même avec un nombre de paramètres réduit. Dans notre pipeline, nous avons utilisé une version pré-entraînée de l'EfficientNetB0. Pour adapter le modèle à notre tâche de classification multi-classes, nous avons supprimé sa couche de sortie d'origine. Afin de spécialiser davantage le modèle pour nos données médicales, les 50 dernières couches ont été "dégelées", permettant ainsi un ajustement ciblé des paramètres via le fine-tuning. La sortie du backbone est condensée à l'aide d'une couche GlobalAveragePooling2D. Elle est ensuite transmise à une structure dense personnalisée, identique à celle employée avec d'autres architectures. Cette structure se compose de trois couches entièrement connectées de tailles décroissantes (512, 256, 128 neurones), toutes activées par la fonction ReLU. Pour renforcer la régularisation et prévenir le surapprentissage, des couches de dropout (avec des taux de 0.4, 0.3 et 0.2) sont insérées. Enfin, une couche softmax finale génère les scores de probabilité pour chaque grade de sévérité.

La figure 3.10 ci-dessous illustre l'architecture d'EfficientNetB0 que nous avons personnalisée pour la classification de l'arthrose.

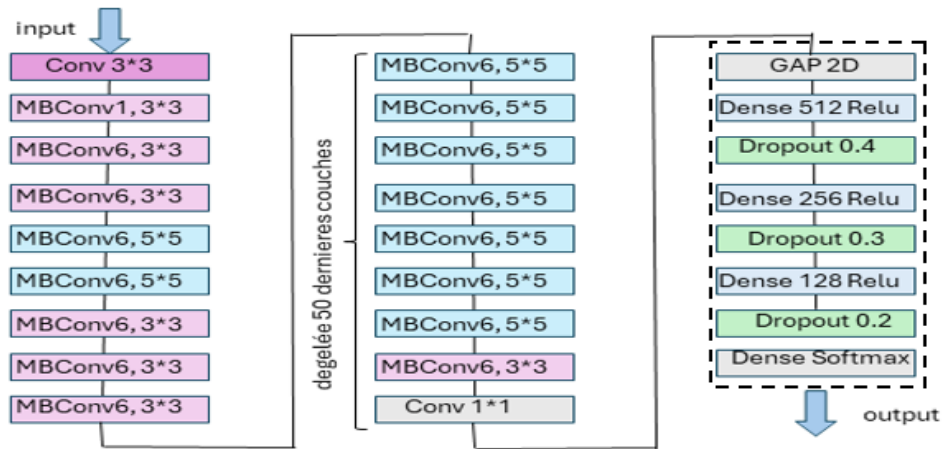


Figure 3.10. Notre architecture personnalisée d'EfficientNetB0.

4.2.4 Notre InceptionV3 adapté pour la Classification de l'Arthrose

L'architecture InceptionV3 se distingue par sa conception modulaire, qui combine simultanément plusieurs tailles de filtres convolutifs au sein d'un même bloc. Cette structure innovante permet d'extraire efficacement des caractéristiques multi-échelles tout en optimisant l'utilisation des ressources de calcul. Dans le cadre de notre étude, nous avons opté pour une version pré-entraînée d'InceptionV3 sur ImageNet. Pour l'adapter à notre tâche spécifique de détection de l'arthrose, nous avons supprimé sa couche de classification finale. Tout en conservant l'essentiel des poids initiaux, un fine-tuning ciblé a été effectué sur les 50 dernières couches du modèle. L'objectif était de renforcer sa capacité à reconnaître les caractéristiques distinctives de l'arthrose. Les sorties du modèle sont ensuite compressées via une couche GlobalAveragePooling2D. Cette couche est suivie de trois couches entièrement connectées, composées respectivement de 512, 256 et 128 neurones, et activées par la fonction ReLU. Pour prévenir le surapprentissage, des couches de dropout (avec des taux de 0.4, 0.3 et 0.2) ont été intercalées. Enfin, une couche softmax assure la sortie des probabilités associées à chaque grade de sévérité de l'arthrose.

La figure 3.11 suivante illustre l'architecture d'InceptionV3 que nous avons personnalisée pour la classification de l'arthrose.

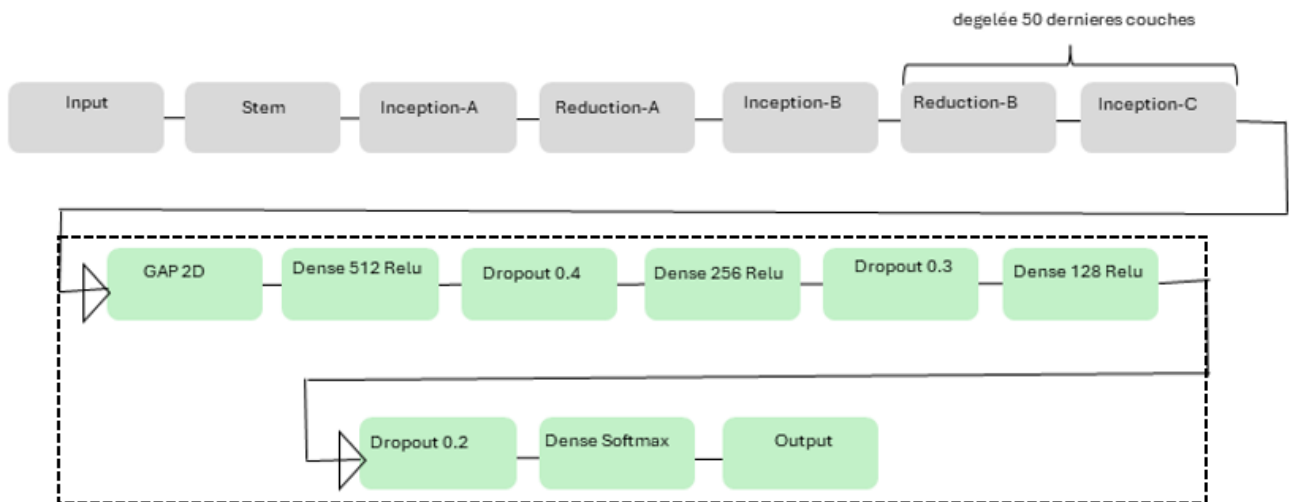


Figure 3.11 Notre architecture personnalisée d’InceptionV3

4.2.5 Notre Mobilenetv2 adapté pour la Classification de l'Arthrose

Nous avons tiré parti de MobileNetV2, une architecture reconnue pour son efficacité et sa légèreté computationnelle, assurant une classification de haute qualité grâce à l'usage de convolutions séparables en profondeur. En utilisant une version pré-entraînée, nous avons retiré sa couche de classification afin de capitaliser sur ses aptitudes apprises sur ImageNet et de les spécialiser pour nos données. Un fine-tuning précis a été réalisé en rendant les 50 dernières couches du modèle entraînaibles, permettant une adaptation optimale aux spécificités de nos images radiographiques. À la sortie du corps extracteur de caractéristiques, une couche GlobalAveragePooling2D est employée pour condenser efficacement les représentations en un vecteur de faible dimension, minimisant la perte d'informations essentielles. Ce vecteur est ensuite alimenté dans une séquence de trois couches denses (512, 256 et 128 neurones), chacune intégrant la fonction d'activation ReLU pour introduire la non-linéarité. Pour renforcer la généralisation du modèle et mitiger le risque de surapprentissage, des couches de dropout avec des taux de 0.4, 0.3 et 0.2 sont appliquées séquentiellement. Enfin, une couche dense de sortie avec une activation softmax est utilisée pour générer les probabilités de classification pour chaque grade de l'arthrose.

La figure 3.12 ci-dessous illustre l'architecture de Mobilenetv2 que nous avons personnalisée pour la classification de l'arthrose.

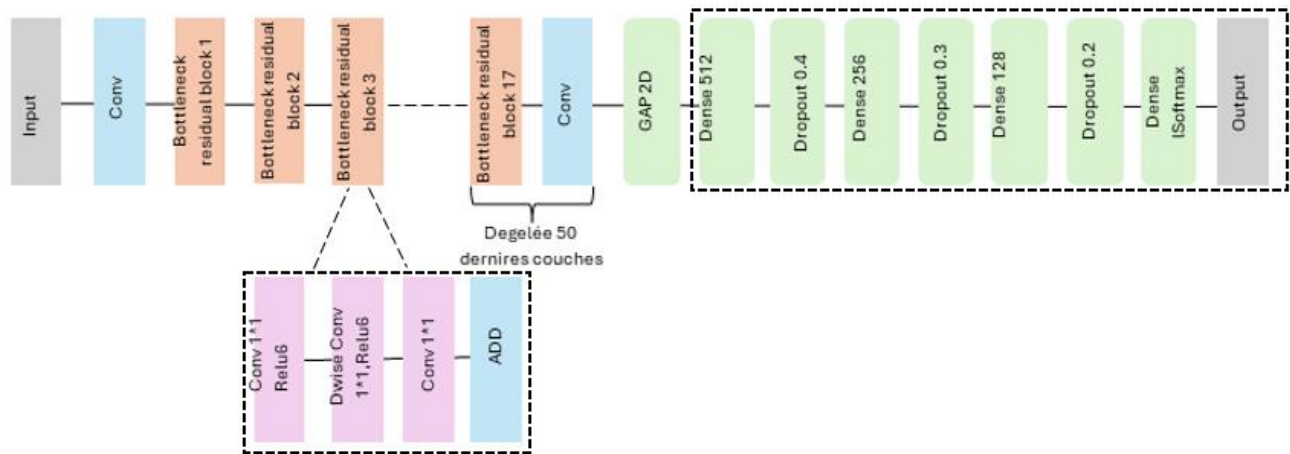


Figure 3.12. Notre architecture personnalisée de Mobilenetv2.

4.3 Explicabilité du modèle

Bien que les modèles d'apprentissage profond offrent des performances remarquables, leur complexité les rend souvent peu interprétables, ce qui leur vaut d'être qualifiés de « boîtes noires ». Cette opacité peut freiner leur adoption, en particulier dans des domaines sensibles comme la santé, où la transparence des décisions algorithmiques est primordiale. Dans certains cas, elle pousse même les utilisateurs à privilégier des méthodes plus simples, au détriment de la performance.

C'est dans ce contexte qu'intervient le concept d'Intelligence Artificielle Explicable (IAX), qui vise à rendre les prédictions plus compréhensibles, en fournissant des justifications claires à l'appui des décisions du modèle.

Dans le domaine médical, où la fiabilité et la transparence sont primordiales, les approches d'IAX prennent une dimension essentielle. Elles permettent notamment de mettre en lumière les régions pertinentes d'une image radiographique, facilitant l'identification de pathologies et renforçant la confiance des professionnels de santé dans les systèmes basés sur l'intelligence artificielle.

Parmi les outils développés dans ce cadre, LIME (Local Interpretable Model-agnostic Explanations) se distingue par son approche indépendante du modèle. Elle fonctionne en générant des perturbations locales d'une instance donnée et en évaluant leur impact sur la prédiction, afin d'identifier les caractéristiques les plus influentes. Cette approche permet de visualiser les régions de l'image ayant guidé la décision, apportant une interprétation locale et intuitive du fonctionnement du modèle [38].

5. Résultats expérimentaux et discussion

Cette partie présente les résultats obtenus lors des différentes expérimentations menées sur les modèles proposés, ainsi que l'analyse de leur performance selon plusieurs configurations. Elle met également en évidence l'impact des choix d'optimisation sur l'efficacité de la classification.

5.1 Hyperparamètres d'optimisation

Afin d'améliorer les performances du modèle et de favoriser une meilleure généralisation, différents hyperparamètres ont été ajustés de manière rigoureuse au cours de cette étude. Ces réglages ont contribué à une progression notable des résultats obtenus. Le tableau 3.3 suivant récapitule les principaux hyperparamètres optimisés.

Hyperparamètre	Valeur
Taille du lot (batch-size)	16
Taux d'apprentissage	0.0001
Nombre d'époques	150
Algorithme d'optimisation	Adam
Fonction de perte	Sparse_categorical_crossentropy

Tableau 3.3. Hyperparamètres optimisés pour l'entraînement du modèle

5.2 Contribution 1 : Optimisation de la classification de l'arthrose du genou sur la base de données KOD-KL-2018

Dans le cadre de notre première contribution, nous avons procédé à une évaluation approfondie de cinq architectures d'apprentissage profond pré-entraînées (DenseNet121, ResNet50, EfficientNetB0, InceptionV3, MobileNetV2). L'objectif était de déterminer leur efficacité pour la classification de l'arthrose du genou à partir d'images radiographiques issues de la base de données Knee Osteoarthritis, répartie en cinq niveaux de sévérité selon le système de Kellgren-Lawrence.

Un protocole expérimental strict a été appliqué pour tester diverses configurations, avec ou sans prétraitement des données. Nous avons ensuite comparé les performances des modèles en utilisant plusieurs métriques clés (accuracy, précision, rappel, F1-score, spécificité, AUC) afin d'identifier les architectures les plus robustes. Cette investigation a également révélé l'impact notable du déséquilibre des classes sur la qualité de la classification, nous incitant à explorer des approches alternatives, notamment la réduction du nombre de classes.

5.2.1 Évaluation comparative de la classification en 5 classes

Dans cette section, nous évaluons la performance de plusieurs modèles de deep learning pour la classification automatique de l'arthrose du genou en cinq classes. L'objectif est d'identifier les architectures les plus efficaces pour distinguer les différents niveaux de sévérité à partir d'images radiographiques, tout en analysant l'impact du déséquilibre de classes sur les résultats. Le tableau 3.4 suivant présente les résultats obtenus pour chaque modèle.

D'après ces résultats, nous constatons que le prétraitement des données joue un rôle déterminant dans l'amélioration des performances des modèles de classification des stades de l'arthrose du genou, entraînant une augmentation significative de l'accuracy pour toutes les architectures évaluées.

Modèle	Prétraitement	Accuracy	Précision	Rappel	F1-Score	Spécificité	AUC
DenseNet121	Sans	64.01 %	70.30 %	67.76 %	69.01 %	90.29%	0.74
	Avec	89.62 %	89.40 %	89.60 %	89.60 %	77.60%	0.99
MobilenetV2	Sans	56.83 %	60.29 %	59.55 %	59.91 %	88,24 %	0.65
	Avec	77.08 %	77.00 %	78.60 %	76.80 %	94.26	0.98
Resnet50	Sans	62.54 %	63.92 %	61.85 %	62.87 %	89,49 %	0.72
	Avec	85.89 %	86.40 %	85.80 %	85.80 %	96.47%	0.98
EfficientNetB0	Sans	60.03 %	63.50 %	61.11 %	62.31 %	89.13%	0.68
	Avec	84.72 %	84.60 %	84.60 %	84.80 %	96.18%	0.96
InceptionV3	Sans	62.20 %	65.46 %	61.61 %	63.48 %	89.6%	0.68
	Avec	89.10 %	89.20 %	89.00 %	89.00 %	97.24	0.95

Tableau 3.4. Évaluation des performances des modèles sur KOD-KL-2018 (5 classes) avant et après prétraitement.

Parmi les modèles testés, DenseNet121 se distingue par ses performances remarquables, atteignant une accuracy de 89.62 % après prétraitement, contre 64.01 % sans traitement préalable. Il affiche également un F1-Score élevé de 89.60 % ainsi qu'une AUC quasi parfaite de 0.99, ce qui confirme son efficacité. InceptionV3 arrive en deuxième position avec une accuracy de 89.10 % après prétraitement, contre 62.20 % avant, accompagnée d'une AUC de 0.95. Les modèles ResNet50 et EfficientNetB0 enregistrent aussi des améliorations notables, atteignant respectivement 85.89 % et 84.72 % d'accuracy après prétraitement. Bien que MobileNetV2 bénéficie également du prétraitement, passant de 56.83 % à 77.08 %, il demeure le modèle le moins performant de l'ensemble.

En résumé, DenseNet121 s'impose comme l'architecture la mieux adaptée à cette tâche de classification. Ces résultats soulignent l'importance du prétraitement, notamment la normalisation, l'équilibrage des classes et l'augmentation des données, pour optimiser l'efficacité des modèles, particulièrement sur des jeux de données déséquilibrés comme celui de l'arthrose du genou.

La figure 3.13 suivante illustre les matrices de confusion des différents modèles après l'application du prétraitement.

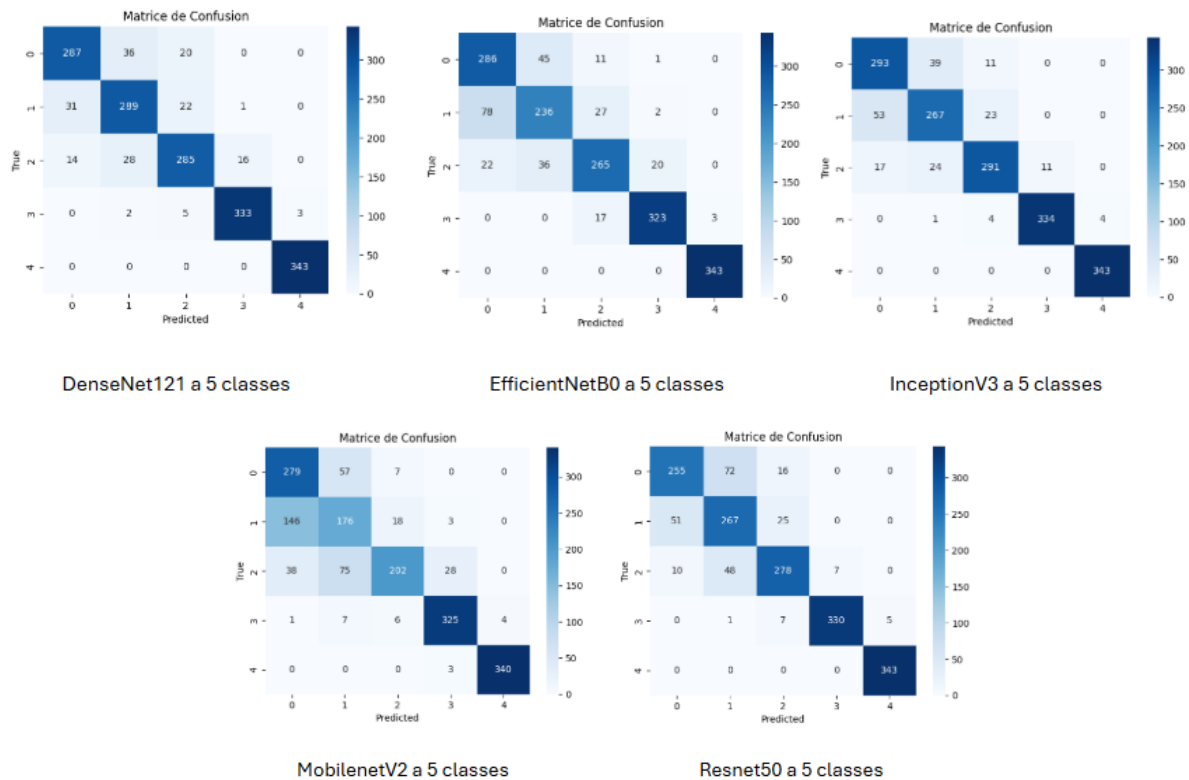


Figure 3.13. Matrices de confusion des différents modèles après application du prétraitement

L'analyse des matrices de confusion met en évidence que les erreurs de classification se concentrent principalement entre les stades voisins de l'arthrose, en particulier entre les classes 0, 1 et 2, en raison de leur similarité visuelle. Le modèle DenseNet121 se distingue par sa capacité à classer correctement l'ensemble des classes, avec une concentration marquée des prédictions le long de la diagonale, en particulier pour les stades avancés 3 et 4. InceptionV3 présente également de bonnes performances, malgré quelques confusions dans les classes intermédiaires. ResNet50 et EfficientNetB0 restent efficaces mais moins précis, tandis que MobileNetV2 affiche plus d'erreurs, notamment entre les classes 1, 2 et 3. Ces résultats confirment la robustesse des modèles pré-entraînés et l'importance du prétraitement pour améliorer la distinction entre des classes visuellement proches.

5.2.2 Expérimentation avec un équilibrage partiel des données

Face aux déséquilibres constatés dans nos cinq classes de données, où la classe majoritaire comptait 2286 images, nous avons implémenté une stratégie d'équilibrage partiel. Plutôt que de nous restreindre à la taille de la classe majoritaire, nous avons choisi d'augmenter le nombre d'images par classe jusqu'à un maximum de 3000. Cette approche vise à mieux répartir les données au sein du jeu de données. C'est crucial pour prévenir le surapprentissage sur la classe majoritaire et pour améliorer les performances globales des modèles d'apprentissage profond. En effet, un meilleur équilibre des données permet aux modèles de mieux généraliser et de capturer les caractéristiques de chaque classe de manière plus robuste. Le tableau 3.5 ci-dessous présente les résultats obtenus avec les différents modèles suite à cette stratégie.

Modèle	Prétraitement	Accuracy	Précision	Rappel	F1-Score	Spécificité	AUC
DenseNet121	Avec	93.91%	94%	94%	94%	98.5%	0.99
MobilenetV2	Avec	84.89%	86%	84%	84%	96.2%	0.98
Resnet50	Avec	90.04%	90%	90%	90%	97.51%	0.99
EfficientNetB0	Avec	81.20%	81%	81%	81%	95.30%	0.97
InceptionV3	Avec	90.44%	90%	90%	90%	97.61%	0.99

Tableau 3.5. Performances des modèles sur KOD-KL-2018 (5 classes) après prétraitement.

Grâce au prétraitement et à l'équilibrage partiel des données, le modèle DenseNet121 a obtenu d'excellentes performances sur le jeu de données KOD-KL-2018 (5 classes). Avec une accuracy de 93.91 %, un F1-score de 94%, une spécificité de 98.5 % et une AUC de 0.99, il démontre une capacité de classification de l'arthrose du genou à la fois précise, équilibrée et hautement fiable, confirmant ainsi son efficacité dans ce contexte. La figure 3.14 suivante montre la répartition des classes après équilibrage, ainsi que la matrice de confusion associée.




Figure 3.14. Distribution des Classes Équilibrées et Matrice de Confusion (DenseNet121)

La matrice de confusion révèle des performances globales satisfaisantes du modèle, avec des taux de classification élevés pour la majorité des classes. Notamment, les classes 3 et 4 affichent des performances remarquablement bonnes, avec un nombre d'erreurs minimale. Cependant, les erreurs de classification se concentrent principalement entre les stades voisins de l'arthrose, soit les classes 0, 1 et 2, suggérant une similarité visuelle entre ces catégories. Ce chevauchement, particulièrement marqué entre les classes 1 et 2, demande une attention particulière pour d'éventuelles améliorations du modèle, telles que l'élargissement des données d'entraînement ou l'ajustement de l'architecture du modèle. Malgré ces confusions localisées, la prépondérance de prédictions correctes atteste d'un modèle globalement robuste et fiable pour la tâche de classification.

5.2.3 Reconfiguration de la classification en 4 classes

Pour améliorer les performances des modèles, nous avons exploré deux configurations expérimentales. Dans la première, nous avons retiré la classe 0, correspondant à un genou sain avec 2286 images, en raison de sa faible pertinence clinique et de sa représentation moindre. Dans la seconde, nous avons supprimé la classe 1, qui regroupe les cas de rétrécissement articulaire douteux, souvent source d'ambiguïté et de confusion pour les modèles. Ces ajustements visent à simplifier la classification et à favoriser une meilleure différenciation des classes restantes.

5.2.3.1 Suppression de la classe 0 (genou sain)

Pour améliorer les performances des modèles, nous avons testé plusieurs approches de classification. L'analyse initiale des cinq classes a révélé une confusion significative entre la classe 0 (genoux sains) et la classe 1 (arthrose très précoce), principalement due à leur similarité visuelle, ce qui entraînait un nombre élevé de faux positifs et de faux négatifs. Afin d'optimiser la détection des pathologies, nous avons donc choisi de retirer la classe 0, réduisant ainsi la classification à quatre classes (KL1 à KL4). Les performances de chaque modèle dans cette configuration spécifique sont résumées dans le tableau 3.6 ci-après, ce qui permettra d'évaluer l'effet de cette stratégie.

Modèle	Prétraitement	Accuracy	Précision	Rappel	F1-Score	Spécificité	AUC
DenseNet121	Sans	65.24 %	68.46 %	67.43 %	67.94 %	86.41%	0.76
	Avec	92.64 %	92.50 %	92.75 %	92.75 %	97.55%	0.96
MobilenetV2	Sans	64.09 %	66.96 %	67.52 %	67.23 %	85.95%	0.75
	Avec	91.32 %	91.25 %	91.10 %	91.25 %	97.11%	0.99
Resnet50	Sans	63.81 %	68.45 %	66.92 %	67.67 %	85.62%	0.74
	Avec	91.21 %	91.50 %	91.25 %	91.25 %	97.07%	0.99
EfficientNetB0	Sans	65.38 %	68.47 %	68.30 %	68.38 %	86.5%	0.75
	Avec	89.89 %	89.85 %	89.85 %	89.85 %	96.63%	0.99
InceptionV3	Sans	65.81 %	69.70 %	68.76 %	69.23 %	86.6%	0.76
	Avec	90.66 %	90.75 %	90.75 %	90.75 %	96.89%	0.99

Tableau 3.6. Évaluation des performances des modèles sur KOD-KL-2018 (4 classes) avant et après prétraitement.

L'analyse des résultats montre clairement que le prétraitement des données joue un rôle déterminant dans la performance des modèles de classification appliqués aux images radiographiques du genou. Sans cette étape, les cinq modèles examinés (DenseNet121, MobileNetV2, ResNet50, EfficientNetB0 et InceptionV3) affichent une accuracy et un F1-score modestes, compris entre 64 % et 69 %. Leur capacité de discrimination reste également limitée, avec une AUC d'environ 0,75. Ces résultats traduisent la difficulté des modèles à interpréter correctement des images brutes de qualité variable.

Après prétraitement, l'accuracy et le F1-score s'améliorent de façon significative pour tous les modèles, dépassant 89 %, tandis que l'AUC atteint des valeurs proches de 0.99, témoignant d'une excellente capacité de classification. DenseNet121 s'impose comme le leader avec une accuracy de 92.64% et un F1-score de 92.75 %, suivi de près par MobileNetV2 et ResNet50. InceptionV3 et EfficientNetB0 obtiennent également des résultats très satisfaisants. Ces observations confirment l'efficacité des architectures profondes combinées à une préparation soignée des données, soulignant ainsi l'importance cruciale du prétraitement pour détecter des signes cliniques subtils et différencier les stades d'arthrose, souvent visuellement proches.

La figure 3.15 suivante présente les matrices de confusion obtenues pour chaque modèle après l'application du prétraitement.

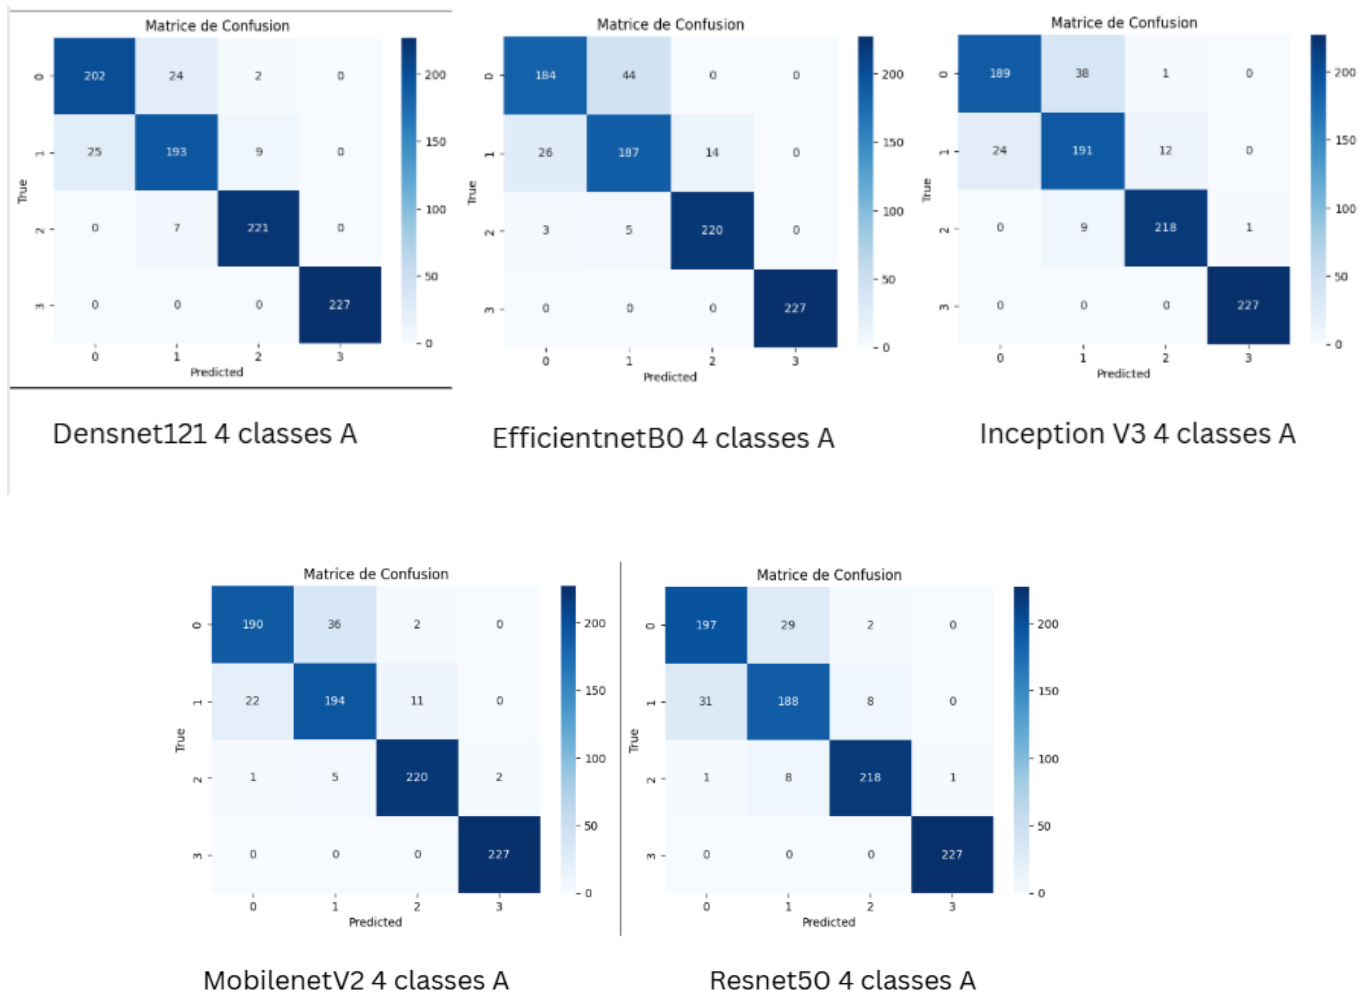


Figure 3.15. Matrices de confusion des différents modèles après prétraitement sur KOD-KL-2018 (classification en 4 classes).

L'analyse des matrices de confusion suite à la suppression de la classe 0 (passant à 4 classes) révèle une amélioration générale des performances des modèles. DenseNet121 demeure le plus performant, affichant une grande précision sur toutes les classes restantes, en particulier les classes 3 et 4. MobileNetV2 se positionne en deuxième place, suivi de très près par ResNet50. InceptionV3 et EfficientNetB0 affichent également de solides performances, bien qu'avec un nombre légèrement plus élevé de confusions que les leaders. Les erreurs résiduelles se concentrent principalement entre les classes adjacentes 1 et 2, soulignant la difficulté inhérente à les distinguer visuellement. Cette configuration simplifiée améliore la capacité des modèles à différencier les stades pathologiques de l'arthrose.

5.2.3.2 Suppression de la classe 1 (arthrose très précoce)

Initialement, la suppression de la classe 0 n'ayant pas entièrement résolu les problèmes de confusion inter-classes, une nouvelle approche a été adoptée. Pour optimiser la détection des pathologies, il a été décidé de retirer la classe 1 (arthrose très précoce), tout en rétablissant la classe 0. Cette nouvelle configuration réduit également la tâche de classification à quatre classes (KL0, KL2, KL3, KL4). Les résultats obtenus pour chaque modèle dans cette configuration spécifique seront résumés dans le tableau 3.7 suivant, permettant d'évaluer l'impact de ce choix sur leur performance.

Modèle	Prétraitement	Accuracy	Précision	Rappel	F1-Score	Spécificité	AUC
DenseNet121	Sans	80.99 %	81.03 %	79.99 %	80.51 %	92.50%	0.88
	Avec	96.14 %	96.00 %	96.25 %	96.25 %	98.71%	1
MobilenetV2	Sans	78.67 %	78.80 %	77.40 %	78.09 %	91.55%	0.85
	Avec	94.68 %	94.75 %	94.50 %	94.75 %	98.23%	0.99
Resnet50	Sans	80.46 %	81.29 %	78.09 %	79.66 %	92.30%	0.88
	Avec	95.70 %	95.75 %	95.75 %	95.50 %	98.59%	1
EfficientNetB0	Sans	79.62 %	80.08 %	78.22 %	79.17 %	92.15%	0.86
	Avec	95.99 %	96.00 %	96.00 %	96.00 %	98.67%	1
InceptionV3	Sans	81.52 %	81.81 %	80.33 %	81.06 %	91.75%	0.89
	Avec	95.26 %	95.50 %	95.25 %	95.50 %	98.32%	0.99

Tableau 3.7. Comparaison des performances des modèles sur KOD-KL-2018 (4 classes) avant et après l'étape de prétraitement.

L'expérimentation de la suppression de la classe 1 (arthrose très précoce) au profit du rétablissement de la classe 0 (genou sain) a radicalement amélioré la performance de tous les modèles de classification à quatre classes. Le prétraitement des données reste le facteur clé, propulsant toutes les métriques à des niveaux très élevés, avec des Accuracy dépassant 94% et des AUC proches de 1. Dans cette configuration, DenseNet121 se distingue comme le plus performant, suivi de près par EfficientNetB0 en deuxième position, avec des précisions et F1-Scores supérieurs à 95% et des AUC parfaits. Cette amélioration significative suggère que la classe 1 était particulièrement difficile à discriminer, et sa suppression a permis aux modèles de mieux se concentrer sur la détection et la différenciation des autres stades de l'arthrose.

La figure 3.16 suivante présente les matrices de confusion obtenues pour chaque modèle après l'application du prétraitement.

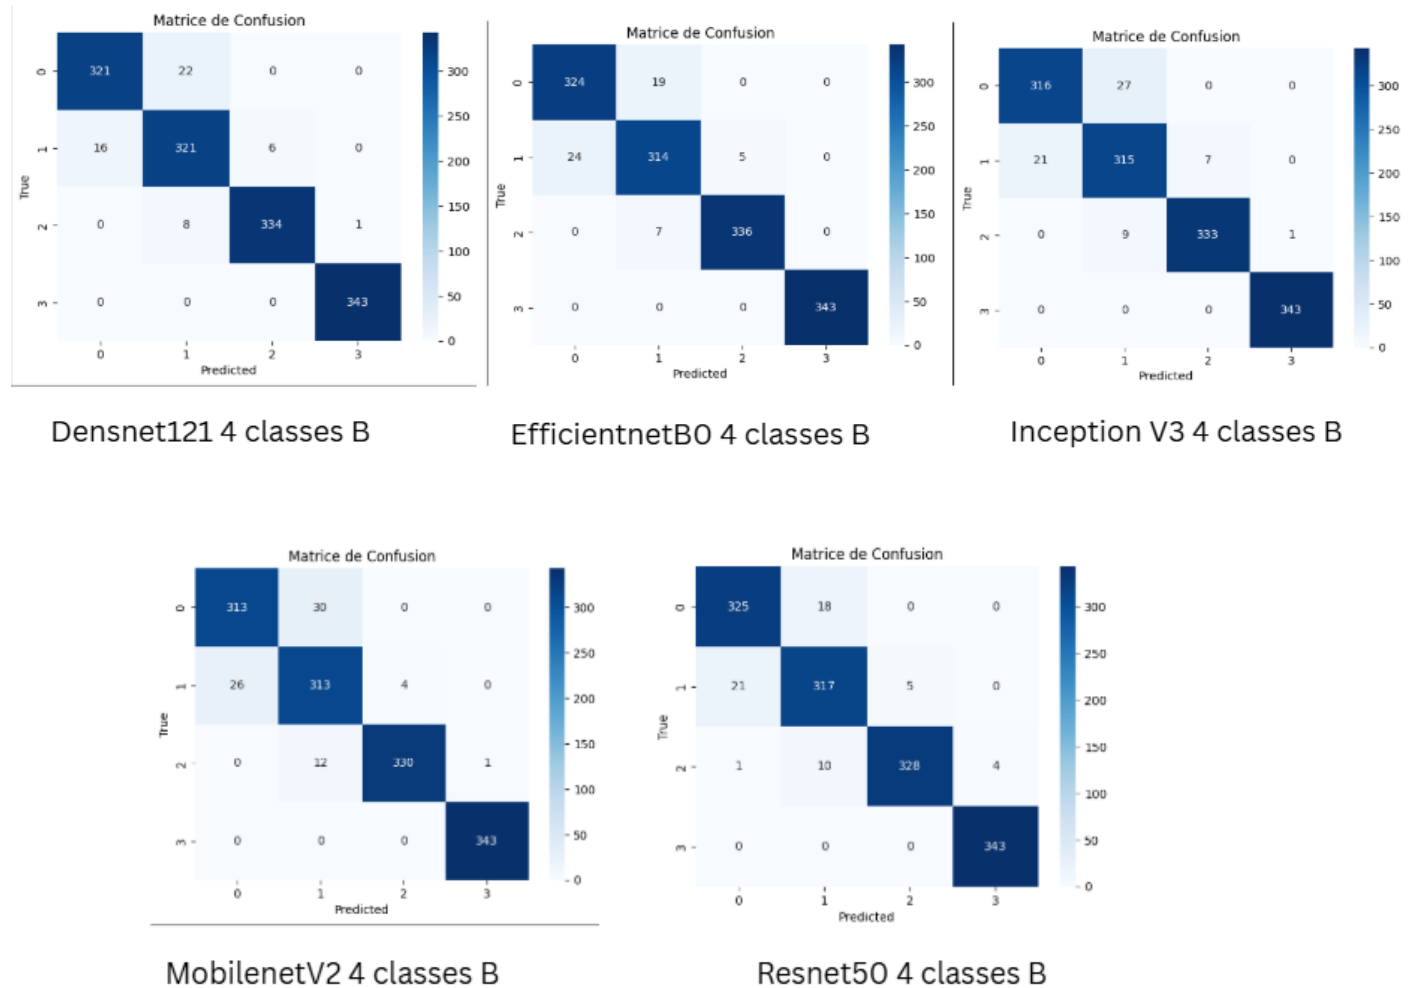


Figure 3.16. Performances des modèles après prétraitement : Matrices de confusion pour la classification en 4 classes sur le jeu de données KOD-KL-2018.

La suppression de la classe 1 (arthrose très précoce) et le rétablissement de la classe 0 (genou sain) ont conduit à une nette amélioration des performances de classification pour l'ensemble des modèles étudiés. Dans cette configuration à quatre classes, les matrices de confusion démontrent une capacité accrue à différencier les stades de l'arthrose, avec une augmentation notable des valeurs sur la diagonale principale de chaque matrice, indiquant un nombre élevé de prédictions correctes. En particulier, DenseNet121 se distingue comme le plus performant, affichant très peu d'erreurs résiduelles. EfficientNetB0 se positionne en seconde place, ses performances étant très proches de celles de DenseNet121. Les autres architectures, telles que ResNet50, InceptionV3 et MobileNetV2, bénéficient également de cette nouvelle configuration, avec des erreurs réduites et

une meilleure différenciation des stades d'arthrose ; MobileNetV2, notamment, montre une nette progression par rapport aux configurations précédentes. Les erreurs résiduelles sont désormais moins fréquentes et plus dispersées, ce qui suggère que la suppression de la classe 1 a efficacement éliminé une source majeure d'ambiguïté pour l'apprentissage des modèles, confirmant ainsi que cette configuration est la plus appropriée pour une classification précise et fiable des images radiographiques du genou.

5.2.4 Analyse comparative des différentes configurations

L'étude approfondie des configurations de classification met en lumière l'importance primordiale du prétraitement des données et de l'ajustement des classes pour l'optimisation des modèles d'apprentissage profond. Initialement, la classification à cinq classes (KL0 à KL4) présentait une performance correcte, mais souffrait de confusions notables entre les classes adjacentes (0, 1, 2) en raison de leur similarité visuelle ; les stades avancés (3 et 4) étant, quant à eux, très bien identifiés. L'expérimentation de la suppression de la classe 0 (genoux sains) a certes apporté une amélioration globale, mais n'a pas résolu intégralement les problèmes de confusion, notamment entre les classes 1 et 2, qui restaient visuellement difficiles à distinguer.

La stratégie la plus efficace s'est avérée être la suppression de la classe 1 (arthrose très précoce) et le rétablissement de la classe 0. Cette configuration à quatre classes (KL0, KL2, KL3, KL4) a entraîné une amélioration spectaculaire des performances pour tous les modèles. La classe 1, identifiée comme la principale source d'ambiguïté, a vu son retrait favoriser une discrimination bien plus nette des autres stades. Il est à noter que, quelle que soit la configuration, le prétraitement des données a toujours été un facteur déterminant, propulsant les métriques de performance telles que l'accuracy et l'AUC à des niveaux quasi parfaits.

En ce qui concerne les modèles, DenseNet121 s'est constamment imposé comme le plus performant, démontrant une précision et une fiabilité exceptionnelles. Dans la configuration finale la plus performante (avec suppression de la classe 1), EfficientNetB0 s'est distingué en deuxième position, affichant des performances très proches de celles de DenseNet121. Les autres modèles, tels que ResNet50, InceptionV3 et MobileNetV2, ont également bénéficié significativement de ces optimisations de configuration, confirmant l'efficacité des architectures profondes combinées à une stratégie de classification affinée.

5.2.5 Évaluation des Prédictions sur la Base de Test

Pour valider l'entraînement de notre modèle DenseNet121, nous avons effectué des prédictions sur des exemples choisis de la base de test du jeu de données KOD-KL-2018. La Figure 3.17

illustre ces résultats, montrant que les images sont correctement classées, chaque prédiction correspondant à la classe réelle de l'image.



Figure 3.17 Résultats de prédiction pour la base de données KOD-KL-2018

5.2.6 Comparaison de nos résultats avec l'état de l'art

Le tableau suivant présente une comparaison des taux de classification (TC) de nos résultats avec les approches existantes. L'ensemble des travaux comparés a été évalué sur le même jeu de données KOD-KL-2018.

<i>Auteurs</i>	<i>Méthodes</i>	<i>TC (%)</i>
Abdul et al [24]	ResNet101	89
Jain et al [25]	InceptionV3	91
Kumar et al [27]	EfficientNetB7	78.53
Ren et al. [29]	ResNet et MobileNet avec fusion multi-échelle	84.88
Wang et al [31]	Autoencodeur Convolutionnel (CAE) avec mécanismes d'attention	91.86
Nos Méthodes	Étape de prétraitement + DenseNet121 personnalisé	89.62
	Étape de prétraitement + équilibrage partiel des données + DenseNet121 personnalisé	93.91
	Étape de prétraitement avec suppression de la classe 0 + DenseNet121 personnalisé	92.64
	Étape de prétraitement avec suppression de la classe 1 + DenseNet121 personnalisé	96.14

Tableau 3.8. Évaluation comparative de nos méthodes de classification par rapport aux approches existantes sur le jeu de données KOD-KL-2018.

Notre étude met en évidence des performances supérieures à celles des approches existantes, en particulier grâce à notre méthode optimisée combinant une étape de prétraitement avec la suppression de la classe 1 et l'utilisation d'un DenseNet121 personnalisé. Cette configuration permet d'atteindre un taux de classification remarquable de 96.14 %. Ce résultat dépasse largement les performances rapportées dans les travaux récents de la littérature. Par exemple, notre méthode surpasse ResNet101 (89 %) d'Abdul et al. [24], EfficientNetB7 (78.53 %) de Kumar et al. [27], InceptionV3 (91 %) de Jain et al. [25], ainsi que l'approche de fusion multi-échelle basée sur ResNet et MobileNet (84.88 %) proposée par Ren et al. [29]. De plus, notre approche dépasse également celle de Wang et al. [31], qui utilise un autoencodeur convolutionnel avec mécanismes d'attention et atteint un taux de classification de 91.86 %.

Ces résultats mettent en évidence l'efficacité de nos stratégies de prétraitement et d'ajustement des classes. En particulier, la suppression de la classe 1 s'est avérée cruciale pour affiner la tâche de classification et maximiser la performance du DenseNet121. De plus, nos différentes configurations explorées (prétraitement seul, prétraitement avec équilibrage partiel, prétraitement avec suppression de la classe 0) confirment l'apport progressif de chaque étape à la performance finale, avec des taux de classification allant de 89.62 % à 93.91 % et 92.64 % respectivement avant d'atteindre le pic de 96.14 %.

5.3 Contribution 2 : Validation sur le jeu de données annoté pour la détection de l'arthrose du genou (AD-KAD)

Cette deuxième contribution a pour objectif de valider la capacité de généralisation de nos modèles en les évaluant sur le jeu de données AD-KAD. Il s'agit d'une étape déterminante pour vérifier si les optimisations de prétraitement et de classification issues de KOD-KL-2018 conservent leur efficacité sur ce nouveau jeu de données, confirmant ainsi leur potentiel en pratique clinique.

5.3.1 Évaluation des modèles et effet du prétraitement sur AD-KAD

Cette partie évalue les performances de nos modèles sur le jeu de données AD-KAD, soulignant la robustesse de nos approches et l'efficacité continue du prétraitement dans la classification de l'arthrose du genou. Le tableau 3.9 des résultats détaillera les métriques obtenues par chaque modèle, avec et sans prétraitement.

Modèle	Prétraitement	Accuracy	Précision	Rappel	F1-Score	Spécificité	AUC
DenseNet121	Sans	80.24 %	83.60 %	80.00 %	95.80 %	94.56%	0.95
	Avec	93.01 %	93.00 %	93.20 %	93.00 %	98.25 %	0.99
MobilenetV2	Sans	72.58 %	53.40 %	66.40 %	65.20 %	93.11%	0.94
	Avec	89.12 %	89.20 %	89.20 %	93.20 %	97.26%	0.99
Resnet50	Sans	82.26 %	81.00 %	81.20 %	81.00 %	94.82%	0.92
	Avec	92.23 %	92.28 %	92.22 %	92.22 %	98.05%	0.94
EfficientNetB0	Sans	72.18 %	72.20 %	71.40 %	74.20 %	92.93%	0.91
	Avec	91.45 %	91.60 %	91.40 %	91.20 %	97.87%	0.98
InceptionV3	Sans	77.82%	70.40 %	69.60 %	71.00 %	94.12%	0.95
	Avec	93.26 %	93.60 %	93.20 %	93.20 %	98.31%	0.99

Tableau 3.9. Comparaison des performances des modèles sur le jeu de données AD-KAD avant et après prétraitement.

L'évaluation sur le jeu de données AD-KAD confirme le fort potentiel de généralisation de nos modèles. Le prétraitement des données joue un rôle clé en améliorant de manière significative toutes les métriques pour chaque modèle testé. Par exemple, la précision de MobileNetV2 passe de 53.40% à 89.20%, soit une amélioration de près de 36%. Le rappel de ce modèle connaît également une progression marquée, passant de 66.40% à 89.20%, ce qui représente un gain de près de 23%. Ces améliorations sont particulièrement importantes dans le domaine médical, car elles permettent de réduire les faux négatifs et d'identifier plus efficacement les cas positifs d'arthrose, contribuant ainsi à limiter les erreurs de diagnostic. Elles illustrent également la robustesse de l'étape de prétraitement, indépendamment du jeu de données initial utilisé, en l'occurrence KOD-KL-2018.

DenseNet121 et InceptionV3 se distinguent par leur haute précision, autour de 93%, et des AUC proches de 0,99, garantissant une séparation nette entre les classes. Leur rappel atteint également 93,20%, traduisant une excellente capacité à détecter les cas positifs. Les autres modèles, comme ResNet50 et EfficientNetB0, affichent également une solide capacité de généralisation. Ces résultats démontrent que nos stratégies d'optimisation sont transférables et pertinentes pour une intégration clinique dans l'aide au diagnostic de l'arthrose du genou.

La figure 3.18 suivante présente les matrices de confusion obtenues pour chaque modèle après l'application du prétraitement.

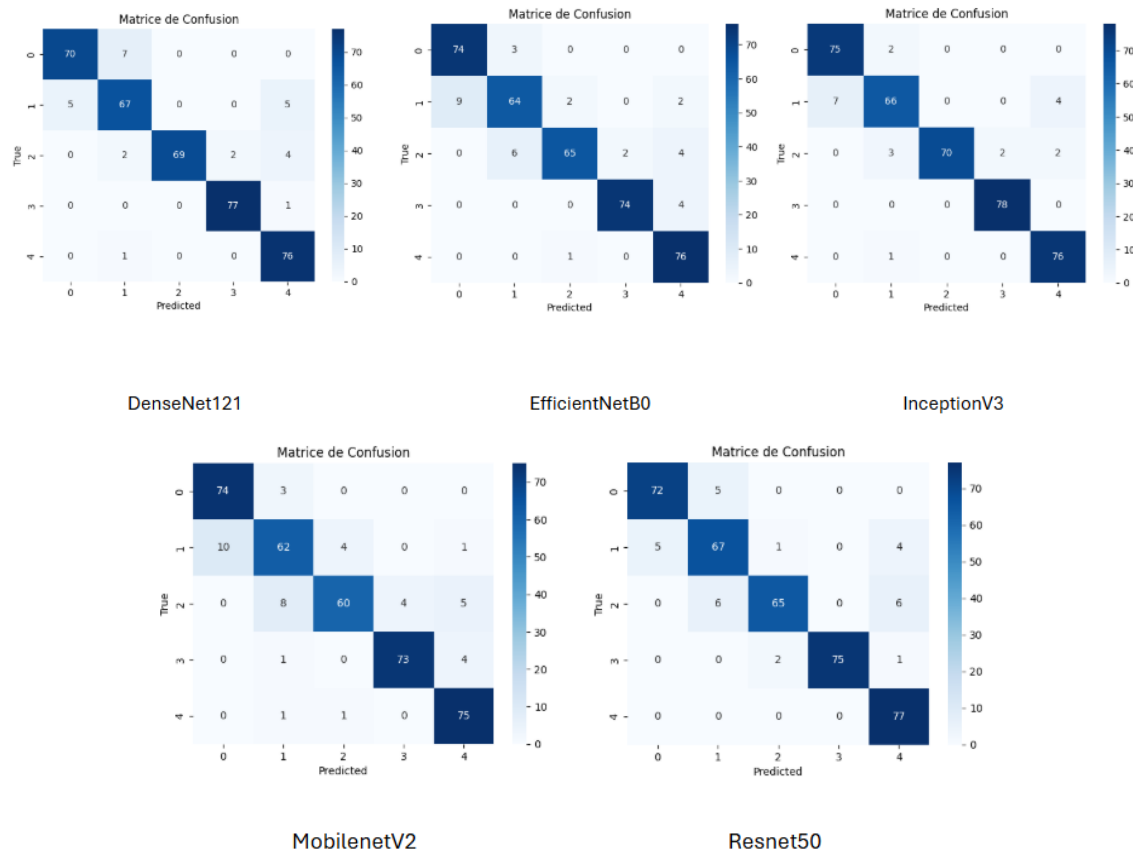


Figure 3.18. Performances des modèles après prétraitement : Matrices de confusion pour la classification sur le jeu de données AD-KAD.

Les matrices de confusion générées après l'application du prétraitement sur le jeu de données AD-KAD confirment la grande précision et la capacité de généralisation de l'ensemble des modèles. La forte concentration des valeurs sur la diagonale principale de chaque matrice témoigne d'un nombre important de prédictions correctes, illustrant la robustesse des modèles face à des données externes.

Plus précisément, DenseNet121 et InceptionV3 se distinguent par leurs performances les plus élevées, affichant une grande précision pour les stades extrêmes (KL0 et KL4) et un rendement équilibré sur l'ensemble des classes. InceptionV3, en particulier, se révèle d'une solidité générale remarquable, le positionnant comme le choix optimal pour un soutien au diagnostic fiable. EfficientNetB0, bien que performant, présente légèrement plus d'erreurs entre les classes voisines.

Toutefois, une difficulté commune à tous les modèles réside dans l'identification des phases intermédiaires (KL1-KL3), ce qui souligne la complexité clinique de leur distinction. Les modèles maintiennent une haute spécificité pour les cas sévères (KL4), essentielle en diagnostic médical, avec moins de 5% de faux positifs. ResNet50 affiche une très bonne fiabilité, tandis que

MobileNetV2, malgré sa légèreté, réalise une performance solide. Ces visualisations renforcent les résultats numériques élevés (précision, rappel, AUC) obtenus précédemment et confirment l'efficacité de nos approches pour l'aide au diagnostic clinique.

5.3.2 Comparaison de nos résultats avec l'état de l'art

Le tableau 3.10 suivant présente une comparaison des taux de classification (TC) de nos modèles par rapport à des approches existantes, toutes évaluées sur le même jeu de données AD-KAD. Cette analyse démontre une amélioration significative et systématique de nos résultats par rapport aux travaux de Delveen et al. [28], y compris sur des architectures communes.

<i>Auteurs</i>	<i>Méthodes</i>	<i>TC (%)</i>
Delveen et al. [28]	EfficientNetB0	88.18 %
	Exception Net	77.58%
	ResNet RS101	78.18%
	RegNet Y032	80.61%
	Efficient NetV2B0	85.45%
Nos méthodes	Étape de prétraitement + DenseNet121 personnalisé	93.01%
	Étape de prétraitement + MobileNetV2 personnalisé	89.12%
	Étape de prétraitement + ReseNet50 personnalisé	92.23%
	Étape de prétraitement + EfficientB0 personnalisé	91.45%
	Étape de prétraitement + InceptionV3 personnalisé	93.26%

Tableau 3.10. Évaluation comparative de nos méthodes de classification par rapport aux approches existantes sur le jeu de données AD-KAD.

Ce Tableau met en évidence la performance supérieure de nos méthodes de classification pour la détection de l'arthrose du genou sur le jeu de données AD-KAD, surpassant les approches comparées de Delveen et al. [28]. L'intégration d'une étape de prétraitement et la personnalisation de chaque architecture ont conduit à des taux de classification systématiquement plus élevés. Notamment, notre implémentation d'EfficientNetB0 (91.45%) surpasse celle de la référence (88.18%), et notre MobileNetV2 (89.12%) démontre une efficacité remarquable en surpassant plusieurs modèles plus complexes cités par [28]. Les architectures InceptionV3 (93.26%) et DenseNet121 (93.01%) s'imposent comme les plus performantes, confirmant la pertinence de nos stratégies d'optimisation et leur capacité à établir un nouvel état de l'art pour le diagnostic assisté par ordinateur de l'arthrose.

5.4 Contribution 3 : Analyse de l'interprétabilité des modèles

Dans cette troisième contribution, nous abordons un aspect crucial des modèles d'apprentissage profond : leur interprétabilité. Compte tenu de la complexité inhérente aux réseaux de neurones, comprendre les raisons derrière une prédiction spécifique est essentiel, particulièrement dans le domaine médical. Étant donné ses performances supérieures et sa fiabilité démontrée, nous avons choisi d'explorer l'interprétabilité du modèle DenseNet121 à l'aide de l'outil LIME. Cet outil permet de visualiser les régions de l'image ayant le plus contribué à la décision du modèle.

La figure 3.19 suivante présente des radiographies annotées du genou avec les résultats d'interprétabilité générés par LIME. Ces annotations illustrent visuellement les zones ayant le plus influencé les prédictions du modèle de classification. Chaque image correspond à une classe prédite, de 0 à 4, associée probablement à un niveau de sévérité de l'arthrose du genou.



Figure 3.19 Visualisation de l'interprétabilité des prédictions par LIME pour les différentes classes de sévérité de l'arthrose du genou (0 à 4)

L'illustration montre les résultats d'interprétabilité générés par LIME pour différentes classes de sévérité de l'arthrose du genou (0 à 4). Les contours jaunes indiquent les zones de l'image ayant le plus influencé la prédiction du modèle. On observe que, plus la classe est élevée, plus les zones activées sont étendues et concentrées sur les régions pathologiques (interligne articulaire, bords osseux, déformations).

Le modèle LIME effectue une prédiction correcte pour chaque classe, tout en fournissant une explication visuelle cohérente avec les signes cliniques observés. Ces visualisations confirment la cohérence clinique des décisions du modèle, renforçant sa fiabilité et son utilisabilité en contexte médical grâce à une meilleure interprétabilité.

5.5 Contribution 4 : Développement d'une interface graphique interactive

Après avoir démontré la robustesse et la haute performance de nos modèles de classification pour la détection de l'arthrose du genou, la dernière étape de ce mémoire vise à traduire ces avancées techniques en un outil directement exploitable par les professionnels de santé. Cette

section est dédiée au développement d'une interface graphique interactive. Conçue pour faciliter l'intégration de notre solution en pratique clinique, cette interface permet une classification automatique et intuitive de l'arthrose selon les cinq stades de Kellgren et Lawrence, rendant ainsi le diagnostic assisté par ordinateur accessible aux experts. Afin de garantir la fiabilité maximale du système, nous avons naturellement opté pour l'implémentation de notre modèle le plus précis, DenseNet121 pré-entraîné, au cœur de cette application. L'interface a été méticuleusement développée en utilisant les technologies web standards : JavaScript, HTML et CSS, assurant ainsi une flexibilité et une accessibilité optimales.

Les figures suivantes détaillent l'utilisation de l'interface ArthroScan, une application interactive conçue pour la classification efficace de l'arthrose du genou. Elles illustrent le parcours utilisateur, qui débute par une connexion sécurisée des médecins via leurs identifiants professionnels. Suit ensuite la saisie des informations essentielles du patient, telles que le prénom, le nom, l'âge et le sexe. L'étape suivante consiste à télécharger une radiographie du patient pour son analyse, permettant une classification automatique de l'arthrose, comme le montre l'exemple "Classe 2 : Arthrose légère". Enfin, l'interface offre la possibilité de lancer une nouvelle analyse, simplifiant ainsi le processus de diagnostic et de prise en charge des patients.

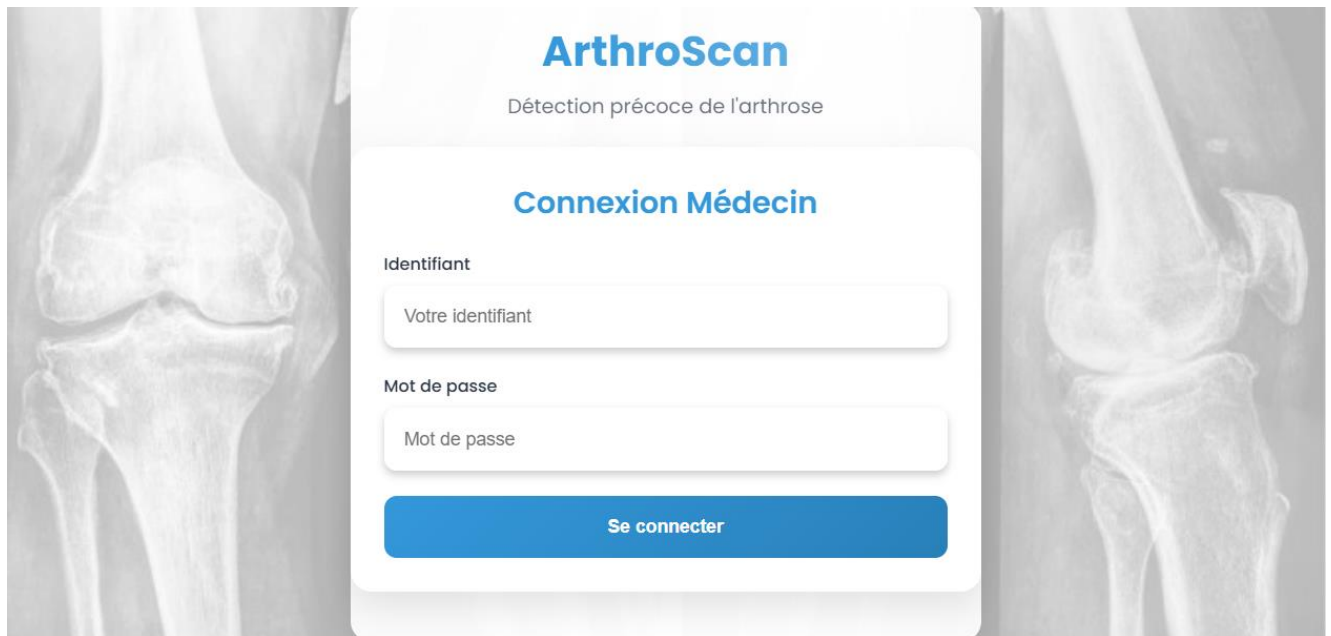
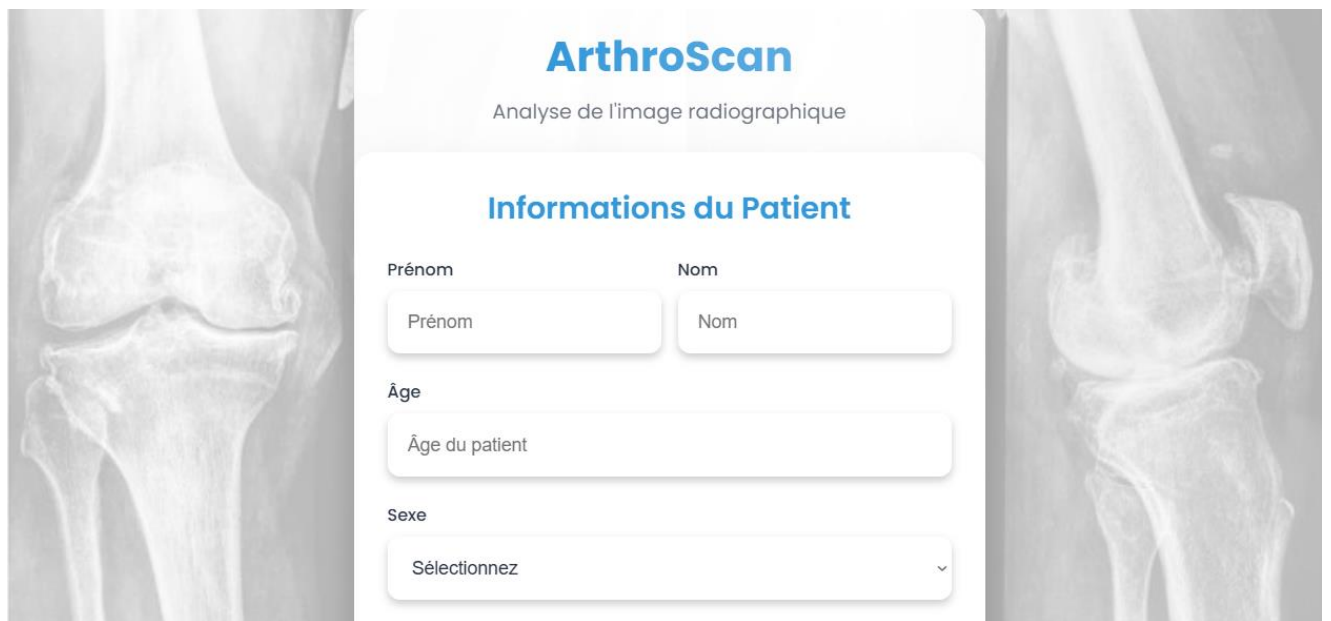
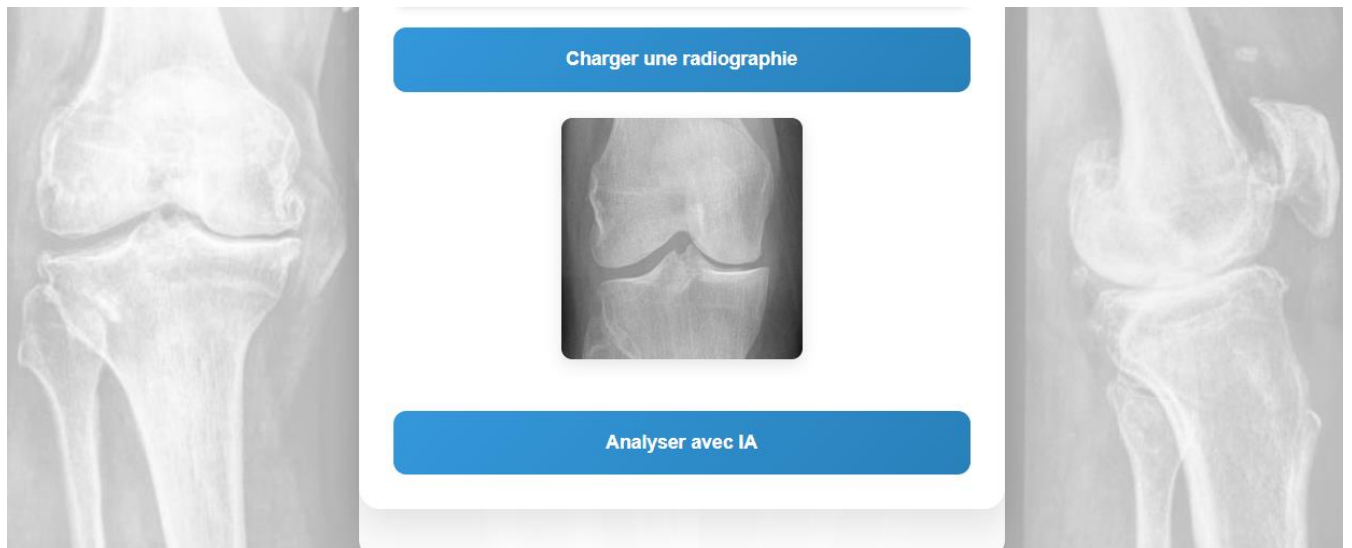


Figure 3.20. Interface de Connexion du Médecin.



The screenshot shows a web interface for 'ArthroScan' with the subtitle 'Analyse de l'image radiographique'. The main heading is 'Informations du Patient'. There are four input fields: 'Prénom' (First Name) and 'Nom' (Last Name) are side-by-side text boxes; 'Âge' (Age) is a text box with the placeholder 'Âge du patient'; and 'Sexe' (Sex) is a dropdown menu with the placeholder 'Sélectionnez'. The interface is flanked by two grayscale X-ray images of a knee joint.

Figure 3.21. Saisie des Informations Patient.



The screenshot shows the next step in the ArthroScan interface. At the top is a blue button labeled 'Charger une radiographie' (Upload X-ray). Below it is a square placeholder for the X-ray image, which currently shows a grayscale X-ray of a knee joint. At the bottom is another blue button labeled 'Analyser avec IA' (Analyze with AI). The interface is flanked by two grayscale X-ray images of a knee joint.

Figure 3.22. Chargement de la Radiographie.



Figure 3.23. Affichage de l'Analyse et des Résultats de Classification.

6. Conclusion

Cette étude met en évidence le potentiel des réseaux de neurones convolutionnels pour la classification de l'arthrose du genou à partir d'images radiographiques. Grâce à des prétraitements adaptés et une optimisation rigoureuse des architectures, nos modèles ont atteint des taux de classification élevés.

La première contribution a porté sur l'optimisation des performances sur le jeu de données KOD-KL-2018, grâce à l'exploration de différentes architectures et stratégies de prétraitement d'images. Dans ce cadre, DenseNet121 s'est révélé être le plus performant, atteignant un taux de classification de 96,14%. La seconde contribution a validé la robustesse des modèles sur un second jeu de données, AD-KAD, démontrant leur capacité de généralisation et leur supériorité par rapport à l'état de l'art. Sur ce jeu de données, InceptionV3 et DenseNet121 se sont avérés être les plus performants, avec des taux de classification élevés dépassant les 93%. La troisième contribution s'est intéressée à l'explicabilité des performances et renommement des modèles l'aide de la méthode LIME, qui a permis de visualiser les zones d'image ayant influencé la décision du modèle, renforçant ainsi la transparence et la confiance dans le système. Enfin, la quatrième contribution a abouti à la création d'une interface graphique nommée ArthroScan, rendant la solution accessible aux professionnels de santé pour une utilisation concrète en milieu clinique.

En résumé, ces travaux prouvent l'efficacité de nos CNN optimisés pour le diagnostic assisté par ordinateur de l'arthrose, ouvrant la voie à de futures recherches et applications cliniques.

Conclusion Générale

Conclusion

L'arthrose est une maladie articulaire dégénérative qui représente un défi majeur de santé publique, affectant considérablement la qualité de vie des patients. Dans ce contexte, ce projet a démontré le potentiel substantiel de l'apprentissage profond pour la détection et la classification automatisées de l'arthrose du genou à partir d'images radiographiques. En relevant des défis majeurs tels que le déséquilibre des données et la nécessité d'une précision clinique élevée, nous avons conçu et évalué une chaîne complète de traitement basée sur l'apprentissage par transfert, utilisant des architectures de réseaux de neurones convolutionnels (CNN) pré-entraînées.

Nos principales contributions incluent une optimisation rigoureuse des performances sur la base de données KOD-KL-2018, où le modèle DenseNet121 a obtenu des résultats particulièrement remarquables, atteignant un taux de classification élevé de 96,14 %. La validation sur le jeu de données AD-KAD a confirmé la robustesse et l'excellente capacité de généralisation de nos modèles, avec InceptionV3 et DenseNet121 atteignant des taux de plus de 93 %. Ces évaluations ont également mis en lumière l'importance cruciale d'un prétraitement adapté, positionnant nos approches favorablement par rapport à l'état de l'art. L'intégration de l'explicabilité via l'outil LIME a par ailleurs renforcé la confiance dans les décisions du modèle en rendant leur logique sous-jacente visible, un aspect essentiel pour une adoption clinique. Enfin, le développement de l'interface graphique interactive ArthroScan a concrétisé ces avancées, transformant notre solution en un outil pratique et accessible qui facilite son intégration dans un environnement clinique réel.

Ce travail ouvre ainsi des perspectives prometteuses pour le diagnostic assisté par ordinateur de l'arthrose du genou. Il pourrait aider à réduire la charge de travail des radiologues, à minimiser les erreurs diagnostiques et à accélérer la prise en charge des patients. Bien que des recherches complémentaires soient nécessaires pour explorer d'autres techniques d'optimisation et valider la généralisation sur des jeux de données encore plus vastes et diversifiés, cette étude confirme la pertinence des modèles d'apprentissage profond comme outils précieux d'aide à la décision en radiologie.

Perspectives

Pour prolonger ce travail, plusieurs pistes d'amélioration et d'extension peuvent être envisagées:

- *Extension à d'autres articulations* : Appliquer la méthodologie développée pour l'arthrose du genou à d'autres articulations souvent touchées par cette maladie, comme

la hanche, la main ou la colonne vertébrale, en adaptant les modèles aux spécificités anatomiques de chaque zone.

- *Intégration de données multimodales* : Combiner les images radiographiques avec d'autres données cliniques (âge, antécédents, biologie) pour un diagnostic plus exhaustif et personnalisé.
- *Détection et segmentation des zones atteintes* : Développer des modèles capables de localiser et de délimiter précisément les lésions sur les radiographies, offrant des informations plus détaillées aux cliniciens.
- *Suivi longitudinal de la progression de l'arthrose* : Créer des modèles prédictifs pour anticiper l'évolution de la maladie à partir de séries d'images.
- *Validation clinique prospective* : Tester l'interface ArthroScan et les modèles en conditions réelles, en collaboration avec des professionnels de santé, afin d'évaluer leur efficacité et leur acceptabilité.

Références bibliographiques

Références bibliographiques

- [1] Wilkins, A. N., Phillips, E. M. (2008). Chapter 130 - Osteoarthritis. Dans W. R. Frontera, J. K. Silver, T. D. Rizzo (Éds.), Essentials of Physical Medicine and Rehabilitation (Second Edition) (pp. 745-751). W.B. Saunders. ISBN 9781416040071.
- [2] La rédaction Futura. (2018, 4 février). Cartilage. Futura-Sciences. Accédé le 21 janvier 2025, à l'adresse <https://www.futura-sciences.com/sante/definitions/medecine-cartilage-3103/>
- [3] Yaseen, K. (2024, avril). Arthrose (Arthrite dégénérative ; Maladie articulaire dégénérative ; Arthrose). Cleveland Clinic. Vérifié/Révisé.
- [4] Organisation Mondiale de la Santé (OMS). (2023, 14 juillet). Arthrose. Accédé le 21 janvier 2025, à l'adresse <https://www.who.int/fr/news-room/fact-sheets/detail/osteoarthritis#>
- [5] Mekideche, Pr. (2022-2023). Service de Médecine Interne. Faculté de Médecine UFAS Sétif 1. [Notes de cours/Polycopié de cours non publié]. Drive : https://drive.google.com/drive/folders/1ej111YLo9PI8fSz704A53B_NhRSZY4x6
- [6] Baillet, O. (2012). Quelle place pour le complément alimentaire dans l'arthrose à l'officine ? , Thèse de doctorat, UFR Sciences Pharmaceutiques et Ingénierie de la Santé, Département Pharmacie.
- [7] Belkacemi, R. (2022-2023). Arthrose. Faculté de Médecine de Tlemcen (5ème année médecine). [Notes de cours/Polycopié de cours non publié, disponible à la bibliothèque de la Faculté de Médecine de Tlemcen].
- [8] Bouterraka, S. (2023). L'intelligence artificielle "Exploration de l'utilisation de ChatGPT" Pour la création de chatbots éducatifs personnalisés Potentielles, Limites et Perspectives, Mémoire de fin d'études. Accédé le 10 juillet 2023, à l'adresse <https://fr.slideshare.net/slideshow/mmoire-pfepdf/259110666>
- [9] Mahboubi, A. (2021, septembre). Automatisation de la sélection des articles scientifiques pour les revues systématiques : Une approche basée sur l'apprentissage automatique, Mémoire de fin d'études, Université de 8 Mai 1945 – Guelma. Accédé à l'adresse https://dspace.univ-guelma.dz/jspui/bitstream/123456789/11771/1/MAHBOUBI_ABDELMOKIM_F5_Informatique.pdf

- [10] Yüksek, G. (2023). L'intelligence artificielle text-to-image" comme outils de support à l'idéation en conception architecturale, Mémoire de fin d'études, Université de Liège – Faculté d'Architecture. Accédé à l'adresse https://matheo.uliege.be/bitstream/2268.2/16936/6/s174654_YÜKSEK_Gizem.pdf
- [11] Elaouaber, Z. A. (2023, 30 septembre). Système d'aide au diagnostic pour la détection automatique du Glaucome et de la Rétinopathie diabétique, Thèse de doctorat, Université Aboubakr Belkaïd – Tlemcen.
- [12] Berkouk, N., & Driouche, S. (2019). Prédiction de flux de trafic routier à l'aide de l'apprentissage profond , Mémoire, Université Mouloud Mammeri de Tizi-Ouzou. Accédé à l'adresse <https://dspace.ummto.dz/server/api/core/bitstreams/27020aac-01f6-4ca0-b021-a68137bc13ee/content>
- [13] Daniella. (2024, 5 juin). Réseau de Neurones Convolutif : fonctionnement, avantages et applications en IA. Innovatiana. Accédé le 27 janvier 2025, à l'adresse <https://www.innovatiana.com/post/convolutional-neural-network>
- [14] Bellahmer, H. (2020). Implémentation et évaluation d'un modèle d'apprentissage automatique pour l'estimation de la valeur marchande de propriétés immobilières, Mémoire, Université Mouloud Mammeri de Tizi-Ouzou. Accédé à l'adresse <https://dspace.ummto.dz/server/api/core/bitstreams/8c9e2b00-cfd5-4286-8070-17b4d906b523/content>
- [15] Cyber Management School. (s.d.). Qu'est-ce que le Transfer Learning (Apprentissage par Transfert) ?. Accédé le 26 janvier 2025, à l'adresse <https://www.cyber-management-school.com/ecole/les-fondamentaux-de-la-cybersecurite/transfer-learning-definition>
- [16] Touahri, R. (2023). L'Apprentissage Profond pour la Classification et l'Interprétation d'Images [Thèse de doctorat, Université de Badji Mokhtar Annaba]. <https://biblio.univ-annaba.dz/wp-content/uploads/2023/03/These-Touahri-Radia.pdf>
- [17] He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 770-778.
- [18] Vellaichamy S., A., et al. (2021). MULTIPLE PLANT LEAF DISEASE CLASSIFICATION USING DENSENET-121 ARCHITECTURE. International Journal of Electrical Engineering and Technology (IJEET), 12, 38-57.
- [19] Barka, N., & Aouni, N. E. (2022). L'Apprentissage Profond pour la detection du covid 19 [Mémoire, Université Kasdi Merbah Ouargla]. <https://dspace.univ-ouargla.dz/jspui/bitstream/123456789/31388/1/08%20Barka-Aouni.pdf>
- [20] MathWorks. (s.d.). InceptionV3. Accédé le 27 avril 2025, à l'adresse <https://www.mathworks.com/help/deeplearning/ref/inceptionv3.html>

- [21] Fadel, O. (2023, juin). Combinaison de classifieurs pour la reconnaissance des anomalies mammaires [Mémoire, Université de 8 Mai 1945 Guelma]. https://dspace.univ-guelma.dz/jspui/bitstream/123456789/14978/1/FADEL_OUISSAL_F5.pdf
- [22] Eskandari, S., Moosavi, S., & Clark, J. (2019). SoK: Transparent Dishonesty: Front-Running Attacks on Blockchain. In *Financial Cryptography and Data Security* (pp. 170–189). Springer. <https://dl.acm.org/doi/abs/10.1145/3446999.3447020>
- [23] Abdullah, S. S., & Rajasekaran, M. P. (2022). Automatic detection and classification of knee osteoarthritis using deep learning approach. *Radiologia Medica*, 127(4), 398-406. <https://doi.org/10.1007/s11547-022-01476-7>
- [24] Mohammed, A. S., Hasanaath, A. A., Latif, G., & Bashar, A. (2023). Knee Osteoarthritis Detection and Severity Classification Using Residual Neural Networks on Preprocessed X-ray Images. *Diagnostics (Basel)*, 13(8), 1380. <https://doi.org/10.3390/diagnostics13081380>
- [25] Kinger, S. (2024). Deep Learning for Automatic Knee Osteoarthritis Severity Grading and Classification. *Journal of Imaging in Ophthalmology*, 58, 1458–1473. <https://doi.org/10.1007/s43465-024-01259-4>
- [26] Mahum, R., Irtaza, A., El-Meligy, M. A., Sharaf, M., Tlili, I., Butt, S., Mahmood, A., & Awais, M. (2023). A Robust Framework for Severity Detection of Knee Osteoarthritis Using an Efficient Deep Learning Model. *International Journal of Computational Biology and Drug Design*, 16(3), 210-226. <https://doi.org/10.1142/S0218001423520109>
- [27] Kumar, L. V. R., et al. (2024). Transfer Learning Based EfficientNet for Knee Osteoarthritis Classification. *Traitement du Signal*, 41(2), 989–997. <https://doi.org/10.18280/ts.410239>
- [28] Alnabi, D. L. A., Ahmed, S. S., & Alnabi, N. L. A. (2025). Knee Osteoarthritis Stage Classification Based on Hybrid Fusion Deep Learning Framework. *Science Journal of the University of Zakho*, 13(2), 263–280. <https://doi.org/10.25271/sjuoz.2025.13.2.1450>
- [29] Ren, X., Hou, L., Liu, S., Wu, P., Liang, S., Fu, H., Li, C., Li, T., & Cheng, Y. (2025). OA-MEN: a fusion deep learning approach for enhanced accuracy in knee osteoarthritis detection and classification using X-Ray imaging. *Frontiers in Bioengineering and Biotechnology*, 12, 1437188. <https://doi.org/10.3389/fbioe.2024.1437188>
- [30] Cinar, I. (2025). Comparative analysis of machine learning and deep learning algorithms for knee arthritis detection using YOLOv8 models. *Journal of Xray Science and Technology*. Publié en ligne avant impression. <https://pubmed.ncbi.nlm.nih.gov/40012222/>
- [31] Wang, X., Wang, T., & Su, Z. (2025). Attention-enhanced deep learning and machine learning framework for knee osteoarthritis severity detection in football players using X-ray images. *Journal of Radiation Research and Applied Sciences*, 18(2), 101428. <https://doi.org/10.1016/j.jrras.2025.101428>
- [32] Futura-Sciences. (s.d.). Python. Accédé le 16 mars 2025, à l'adresse <https://www.futura-sciences.com/tech/definitions/informatique-python-19349/>

- [33] Simplilearn. (s.d.). What is TensorFlow?. Accédé le 16 avril 2025, à l'adresse [https://www-simplilearn-com.translate.google.com/tutorials/deep-learning-tutorial/what-is-tensorflow? x tr sl=en& x tr tl=fr& x tr hl=fr& x tr pto=rq#:~:text=TensorFlow%20is%20an%20opensource,also%20supports%20traditional%20machine%20learnig](https://www.simplilearn.com.translate.google.com/tutorials/deep-learning-tutorial/what-is-tensorflow?x_tr_sl=en&x_tr_tl=fr&x_tr_hl=fr&x_tr_pto=rq#:~:text=TensorFlow%20is%20an%20opensource,also%20supports%20traditional%20machine%20learnig)
- [34] Simplilearn. (s.d.). What is Keras?. Accédé le 16 avril 2025, à l'adresse <https://www.simplilearn.com/tutorials/deep-learning-tutorial/what-is-keras>
- [35] DataCamp. (s.d.). What is Kaggle?. Accédé le 16 avril 2025, à l'adresse <https://www.datacamp.com/fr/blog/what-is-kaggle>
- [36] Kaggle Knee Osteoarthritis Dataset with KL Grading - 2018 Accédé le 02 mars 2025, à l'adresse <https://www.kaggle.com/datasets/tommyngx/kneeoaa/data>
- [37] Kaggle. Annotated Dataset for Knee Arthritis Detection Accédé le 02 mars 2025, à l'adresse <https://www.kaggle.com/datasets/hafiznouman786/annotated-dataset-for-knee-arthritis-detection>
- [38] Steadforce. (s.d.). Explainable AI with LIME. Accédé le 2 mars 2025, à l'adresse <https://www.steadforce.com/blog/explainable-ai-with-lime#:~:text=The%20explainable%20AI%20method%20LIME,therefore%20suitable%20for%20local%20explanations.>