

# GNN pour la classification de la gravité de l’arthrose du genou

Marouane TLIBA<sup>1</sup> Mohamed Amine KERKOURI<sup>2</sup> Yassine NASSER<sup>1</sup> Aladine CHETOUANI<sup>3</sup> Rachide JENNANE<sup>1</sup>

<sup>1</sup> Université d’Orléans, Orléans, France

<sup>2</sup>F-Initiatives, Paris, France

<sup>3</sup> Université Sorbonne Paris Nord, Villetaneuse, France

**Résumé** – L’arthrose du genou (KOA) est une maladie articulaire dégénérative courante, dont le diagnostic repose majoritairement sur l’analyse radiographique via l’échelle de Kellgren–Lawrence (KL). Les approches actuelles en deep learning utilisent des radiographies brutes, souvent perturbées par des artefacts texturaux, masquant les indices morphologiques clés. Nous proposons une méthode morphologique innovante axée sur la structure géométrique de l’articulation, simplifiant le biais inductif du modèle. À l’aide du modèle Segment Anything (SAM), nous extrayons automatiquement des repères anatomiques précis sur le fémur et le tibia. Ces points sont modélisés sous forme de graphes, où les nœuds représentent les repères et les arêtes traduisent des relations géométriques locales et globales. Un classifieur GNN basé sur EdgeConv traite ces graphes pour prédire les grades KL, en capturant efficacement les relations morphologiques inter- et intra-osseuses. Cette approche, invariante aux translations, rotations et changements d’échelle, est la première à exploiter des caractéristiques morphologiques pour l’évaluation de la KOA. Nos expériences montrent des performances de pointe sur différentes configurations de grades KL.

**Abstract** – Knee osteoarthritis (KOA) is a common degenerative joint disease, with its diagnosis primarily based on radiographic analysis using the Kellgren–Lawrence (KL) scale. Current deep learning approaches use raw radiographs, which are often disturbed by textural artifacts that obscure key morphological indicators. We propose an innovative morphological method focused on the geometric structure of the joint, thereby simplifying the model’s inductive bias. Using the Segment Anything Model (SAM), we automatically extract precise anatomical landmarks on the femur and tibia. These points are modeled as graphs, where the nodes represent the landmarks and the edges represent local and global geometric relationships. A GNN classifier based on EdgeConv processes these graphs to predict the KL grades by efficiently capturing both inter- and intra-bone morphological relationships. This approach, invariant to translations, rotations, and scale changes, is the first to leverage morphological features for the evaluation of KOA. Our experiments demonstrate state-of-the-art performance across different KL grade configurations.

## 1 Introduction

L’arthrose du genou (KOA) est une maladie dégénérative caractérisée par l’érosion du cartilage, la formation d’ostéophytes et le remodelage de l’os sous-chondral, souvent évaluée via le système de notation de Kellgren–Lawrence (KL) [7, 4]. Bien que le deep learning (DL) ait montré son potentiel dans l’automatisation de la classification de la sévérité de la KOA [14, 6, 8], les approches courantes se concentrent principalement sur l’analyse des intensités de pixels ou des textures dans les radiographies, sans s’aligner sur les structures anatomiques essentielles à la notation KL. [12] ont proposé un cadre semi-supervisé utilisant *mixup* pour réduire les écarts de distribution dus aux données d’entraînement limitées. Par ailleurs, des méthodes basées sur des vision transformers ont été proposées dans [24, 14, 13] afin d’améliorer la classification de la KOA. Cependant, ces méthodes se focalisent souvent sur les textures locales (par exemple, les motifs trabéculaires) ou sur les intensités globales, sans modéliser explicitement la morphologie osseuse sous-jacente. Cela peut conduire à une surexploitation de caractéristiques fortuites au détriment des structures anatomiques cliniquement validées. En effet, bien que les CNN et Transformers actuels soient compétents pour détecter les gradients d’intensité locaux et les détails texturaux [17, 18, 10], ils négligent souvent les relations géométriques globales qui forment la base de l’évaluation clinique de la KOA. Les indicateurs morphologiques cruciaux — tels que l’alignement fémoro-tibial, le rétrécissement progressif de l’es-

pace articulaire et la configuration précise des ostéophytes — constituent les repères visuels primordiaux pour la gradation clinique réalisée par des radiologues expérimentés.

Pour remédier à cet écart, nous proposons un cadre centré sur la géométrie qui modélise explicitement la morphologie osseuse via des graph neural networks (GNNs). Notre approche imite le raisonnement d’un radiologue : nous segmentons d’abord les contours fémoral et tibial à l’aide du Segment Anything Model (SAM) [9], puis construisons un graphe où les nœuds représentent des repères anatomiques et les arêtes codent des relations géométriques (par exemple, des distances). Un classifieur basé sur EdgeConv [20, 19] traite ce graphe pour extraire simultanément des indices locaux (par exemple, la courbure des ostéophytes) et des indices globaux (tels que l’alignement fémoro-tibial), en adéquation directe avec les critères du système KL. De plus, notre méthode est invariante aux translations, rotations et changements d’échelle, ce qui est essentiel pour gérer la variabilité des radiographies réelles tout en évitant les biais liés aux textures rencontrés dans les modèles existants.

### Contributions principales :

- **Segmentation automatique et construction de graphes.** Nous utilisons le modèle SAM pour isoler précisément les contours osseux et extraire des repères clés, formant ainsi un graphe qui encode explicitement la forme et les relations spatiales essentielles pour l’évaluation de la KOA.

- **Réseau centré sur la morphologie.** Nous développons une architecture basée sur EdgeConv capable de capturer à la fois des indices structurels locaux et globaux, évitant ainsi les biais de texture courants dans les classificateurs reposant uniquement sur les radiographies.
- **Représentation alignée cliniquement.** En se focalisant sur les caractéristiques géométriques, notre approche reflète fidèlement les biomarqueurs radiologiques, améliorant l’interprétabilité et permettant une classification robuste de la sévérité de la KOA en accord avec les critères cliniques.

## 2 Méthodologie

Nous présentons une stratégie basée sur les graphes qui encode explicitement la structure anatomique de l’articulation pour pallier le biais orienté vers la texture courant dans la classification radiographique de l’arthrose du genou (KOA). La figure 1 illustre notre chaîne de traitement globale, qui consiste d’abord à obtenir des masques articulaires de haute fidélité via SAM, puis à construire un graphe morphologique capturant la géométrie fémoro-tibiale, et enfin à appliquer un réseau basé sur EdgeConv pour classer la sévérité de la KOA.

### 2.1 Segmentation et Extraction des Repères

**Génération Automatique des Masques.** Soit une radiographie  $X \in \mathbb{R}^{H \times W \times C}$ . Nous interrogeons le modèle Segment Anything (SAM) [9] avec des grilles denses de points, ce qui produit un ensemble de masques candidats

$$\mathcal{M} = \{m_i \mid i = 1, \dots, M\}.$$

Chaque masque candidat est ensuite évalué par rapport à des modèles osseux préétablis ( $T_U, T_L$ ) en calculant l’intersection sur l’union (IoU). Le masque  $m^*$  présentant la plus grande IoU est considéré comme la délimitation la plus précise de la zone articulaire.

**Construction du Graphe.** À partir du contour de  $m^*$ , nous échantillonnons uniformément  $N$  repères  $\{p_i\}_{i=1}^N$ , où  $p_i = (x_i, y_i) \in \mathbb{R}^2$ , assurant un espacement régulier le long des contours osseux. Ces points forment l’ensemble de sommets  $V = \{p_i\}$  dans un graphe non orienté :

$$G_{\text{joint}} = (V, E).$$

Pour définir  $E$ , nous appliquons une recherche des  $k$ -voisins les plus proches sous une contrainte de distance  $\tau$ . Plus précisément, pour chaque sommet  $p_i \in V$ ,

$$\mathcal{N}(p_i) = \{p_j \mid \|p_i - p_j\|_2 \leq \tau\} \cup \kappa_k(p_i),$$

où  $\kappa_k(\cdot)$  retourne les  $k$  voisins les plus proches. Nous établissons alors

$$E = \{(p_i, p_j) \mid p_j \in \mathcal{N}(p_i)\}.$$

Si  $G_{\text{joint}}$  est initialement déconnecté,  $\tau$  est augmenté itérativement jusqu’à ce que le graphe couvre la région articulaire. Cette représentation morphologique privilégie la géométrie osseuse à l’échelle macroscopique, en évitant les bruits texturaux subtils présents dans les radiographies brutes.

### 2.2 Classification par Modèle de Graphe

**Classification Morphologique via EdgeConv.** Soit  $\mathbf{X}^{(\ell)} \in \mathbb{R}^{|V| \times d_\ell}$  la matrice des caractéristiques des nœuds à la couche  $\ell$ . À chaque couche, nous définissons des *caractéristiques d’arête* à l’aide d’une fonction de mapping asymétrique,

$$\mathbf{e}_{ij} = \phi_\Theta(\mathbf{x}_i, \mathbf{x}_i - \mathbf{x}_j),$$

où  $\mathbf{x}_j$  est un voisin du nœud central  $\mathbf{x}_i$ , et  $\phi_\Theta : \mathbb{R}^{d_\ell} \times \mathbb{R}^{d_\ell} \rightarrow \mathbb{R}^{d_{\ell+1}}$  est une fonction d’encodage non linéaire (par exemple, un MLP) avec des paramètres entraînables  $\Theta$ . Cette opération de convolution adoptée en GNN, désignée sous le nom d’*EdgeConv* [20], a été largement utilisée dans la classification de formes basée sur les GNN, notamment dans les tâches de nuages de points 3D, grâce à sa capacité à modéliser efficacement la structure géométrique locale.

Concrètement, pour chaque nœud  $i$  avec ensemble de voisins  $\mathcal{N}(i)$ , la couche EdgeConv produit des caractéristiques mises à jour en agrégeant les sous-graphes locaux :

$$\mathbf{x}_i^{(\ell+1)} = \max_{j \in \mathcal{N}(i)} \phi_\Theta([\mathbf{x}_i^{(\ell)}, \mathbf{x}_j^{(\ell)} - \mathbf{x}_i^{(\ell)}]),$$

où  $[\cdot, \cdot]$  désigne la concaténation des caractéristiques. L’empilement de plusieurs couches EdgeConv (trois dans notre cas) augmente systématiquement la dimension de  $\phi_\Theta$  et permet de capturer des relations plus profondes entre les repères osseux, ce qui est essentiel pour distinguer les morphologies subtiles associées à la KOA.

**Normalisation du Graphe.** Après chaque couche EdgeConv, nous utilisons GraphNorm [2] afin de maintenir la stabilité des caractéristiques. Pour chaque caractéristique mise à jour du nœud  $\mathbf{x}_i^{(\ell+1)}$ ,

$$\mathbf{g}_i^{(\ell+1)} = \gamma \frac{\mathbf{x}_i^{(\ell+1)} - \mu(\mathbf{x}^{(\ell+1)})}{\sigma(\mathbf{x}^{(\ell+1)}) + \epsilon} + \beta,$$

où  $\mu$  et  $\sigma$  calculent respectivement la moyenne et l’écart-type des caractéristiques des nœuds, et où  $\gamma, \beta$  sont des paramètres entraînables. Cette normalisation favorise la cohérence au sein de chaque graphe et facilite la convergence.

**Couche de Sortie.** Nous agrégeons les caractéristiques de chaque nœud à l’aide d’un pooling global par moyenne et par maximum pour former un vecteur riche en informations morphologiques  $\mathbf{z}$ , lequel est ensuite transformé en logits de sévérité de la KOA par une couche linéaire :

$$\hat{\mathbf{y}} \in \mathbb{R}^C,$$

où  $C$  représente le nombre de grades discrets de KOA. L’entraînement s’effectue via une fonction de coût cross-entropie standard, permettant ainsi au modèle de graphe d’apprendre des embeddings orientés sur la forme et mieux alignés avec les perceptions cliniques de l’arthrose.

## 3 Analyse des Résultats

Nous avons évalué notre approche basée sur les *GNN* dans trois contextes distincts de classification de la KOA : (1) la classification binaire KLG-0 vs. KLG-1, (2) la classification binaire KLG-0 vs. KLG-2 et (3) le scénario multi-classe complet KLG-0–4 sur le jeu de données OAI [5]. Pour chaque tâche, le




FIGURE 1 : Aperçu de notre pipeline : d’abord, SAM est sollicité pour générer des masques candidats  $\mathcal{M}$ . Le meilleur masque  $m^*$  est sélectionné en fonction de l’IoU avec les modèles osseux supérieur et inférieur ( $T_U, T_L$ ). Ensuite, un graphe morphologique  $G_{\text{joint}}$  est construit à partir du contour de l’articulation et traité par le modèle de graphe proposé  $f_{\text{graph}}(\cdot; \Theta)$ . Enfin, une couche linéaire produit les logits de sévérité de la KOA  $\hat{y}$ .

modèle est entraîné et validé sur les labels correspondants, en adoptant le même découpage Train-Test que celui utilisé dans d’autres méthodes de la littérature.

### 3.1 Observations Générales

La Table 3 résume les approches de pointe pour chaque tâche de classification en indiquant à la fois l’exactitude et le F1-Score. Notre solution, basée uniquement sur le graphe, surpasse toutes les méthodes de référence pour chacune des tâches, soulignant l’utilité d’une représentation explicite de la morphologie osseuse pour l’évaluation de la KOA. Cet avantage persiste, que ce soit dans les tâches binaires simples (KLG-0 vs. KLG-1 ou KLG-0 vs. KLG-2) ou dans la classification multi-classe (0–4). Il est notable qu’un modèle reposant uniquement sur les radiographies a souvent du mal à détecter les changements anatomiques subtils, tandis que notre conception axée sur le graphe met en évidence des indices cliniquement pertinents tels que l’alignement fémoro-tibial et la formation d’ostéophytes.

### 3.2 Performance en Classification Binaire

**KLG-0 vs. KLG-1.** La Table 2 (KLG-0 vs. KLG-1) montre que les méthodes existantes atteignent généralement des précisions d’environ 70–75 % [14, 11]. En revanche, notre modèle atteint 85,66 % de précision et un F1-Score de 86,15 %, démontrant ainsi sa capacité à gérer même les stades légers ou douteux de KOA grâce à des représentations précises de la structure osseuse.

**KLG-0 vs. KLG-2.** Pour la classification binaire KLG-0 vs. KLG-2, la Table 1 indique que les travaux antérieurs [24, 22, 15, 1, 11] se situent généralement en dessous de 90 %. Notre modèle reste compétitif avec 88,12 % de précision et 88,20 % de F1-Score, surpassant les meilleures méthodes malgré la complexité associée à la détection de changements modérés de KOA.

### 3.3 Classification Multi-Classe (KLG-0–4)

Enfin, la Table 3 (toutes classes 0–4) compare notre approche aux classificateurs multi-classes de KOA les plus reconnus [1, 16, 3, 21, 14, 13]. La méthode basée sur le graphe atteint une précision de 74,94 % et un F1-Score de 75,19 %, surpassant les résultats SOTA précédents d’environ 2 à 5 %. Dans ce scénario

plus complexe, la capture des changements morphologiques globaux s’avère essentielle pour distinguer les cas limites et les stades avancés de KOA.

TABLE 1 : État de l’art Comparaison sur l’ensemble de tests OAI (KLG-0 vs. KLG-2) [5]

| Model                    | Accuracy (%) | F1-Score (%) |
|--------------------------|--------------|--------------|
| Wang et al. 2024 [24]    | <b>89.80</b> | 87.66        |
| Wang et al. 2023 [22]    | <b>89.54</b> | 87.62        |
| Tiuplin et al. 2018 [15] | 87.33        | 84.82        |
| Antony et al. 2017 [1]   | 85.50        | 81.31        |
| Nasser et al. 2020 [11]  | 82.53        | 83.48        |
| <b>Our - Graph Model</b> | <b>88.12</b> | <b>88.20</b> |

TABLE 2 : État de l’art Comparaison sur l’ensemble de tests OAI (KLG-0 vs. KLG-1) [5]

| Model                    | Accuracy (%) | F1-Score (%) |
|--------------------------|--------------|--------------|
| Wang et al. 2024 [23]    | 70.21        | -            |
| Nasser et al. 2023 [14]  | 74.08        | 69.01        |
| Nasser et al. 2020 [11]  | 69.83        | 70.95        |
| <b>Our - Graph Model</b> | <b>85.66</b> | <b>86.15</b> |

TABLE 3 : État de l’art Comparaison sur l’ensemble de tests OAI (toutes les classes 0-4) [5]

| Model                    | Accuracy     | F1-Score     |
|--------------------------|--------------|--------------|
| Antony et al. 2016 [1]   | 53.40        | 43.00        |
| Antony et al. 2017 [1]   | 63.60        | 59.00        |
| Tiuplin et al. 2018 [16] | 66.71        | -            |
| Chen et al. 2019 [3]     | 69.60        | -            |
| Wang et al. 2022 [21]    | 69.18        | -            |
| Sekhri et al. 2023 [14]  | 70.17        | 67.00        |
| Sekhri et al. 2024 [13]  | 72.40        | 70.00        |
| <b>Our - Graph Model</b> | <b>74.94</b> | <b>75.19</b> |

## 4 Conclusion

Nous avons présenté une approche basée sur des *GNN* entraînés pour la classification de la sévérité de la KOA, s’éloignant ainsi des pipelines radiographiques conventionnels qui mettent souvent l’accent sur la texture locale au détriment

de la géométrie osseuse globale. En échantillonnant des repères articulaires clés et en les modélisant via un réseau de neurones spécialisé (EdgeConv), nous introduisons un biais inductif centré sur la morphologie, mieux aligné avec les critères cliniques. Cette conception permet de contourner la nature à haute dimension des radiographies brutes, de détourner le modèle des artéfacts d'intensité fortuits et de mettre en évidence les changements structuraux macroscopiques essentiels pour le diagnostic de la KOA. Nos résultats, confirmés par des performances de pointe sur le complexe jeu de données OAI [5], confirment notre hypothèse selon laquelle l'accent mis sur les indices morphologiques — plutôt que sur des détails purement pixel par pixel — offre des gains significatifs en termes d'interprétabilité et de performance pour des tâches complexes de classification de la KOA.

## Références

- [1] Joseph ANTONY *et al.* : Automatic detection of knee joints and quantification of knee osteoarthritis severity using convolutional neural networks. In *MLDM 2017*, pages 376–390, New York, NY, USA, 2017. Springer.
- [2] Tianle CAI *et al.* : Graphnorm : A principled approach to accelerating graph neural network training. In *International Conference on Machine Learning (ICML)*, 2020. Available at : <https://api.semanticscholar.org/CorpusID:221516279>.
- [3] Pingjun CHEN *et al.* : Fully automatic knee osteoarthritis severity grading using deep neural networks with a novel ordinal loss. *Computerized Medical Imaging and Graphics*, 75:84–92, 2019.
- [4] D. HAYASHI *et al.* : Imaging for osteoarthritis. *Annals of Physical and Rehabilitation Medicine*, 59(3):161–169, 2016.
- [5] Osteoarthritis Initiative INVESTIGATORS : Osteoarthritis initiative (oai) data, 2006.
- [6] Mushrat JAHAN *et al.* : Koa-cctnet : An enhanced knee osteoarthritis grade assessment framework using modified compact convolutional transformer model. *IEEE Access*, 2024.
- [7] J. H. KELLGREN et J. LAWRENCE : Radiological assessment of osteo-arthritis. *Annals of the Rheumatic Diseases*, 16(4):494–502, 1957.
- [8] Richard KIJOWSKI *et al.* : Deep learning applications in osteoarthritis imaging. *Skeletal Radiology*, 52(11):2225–2238, 2023.
- [9] Alexander KIRILLOV *et al.* : Segment anything. In *Proceedings of the IEEE/CVF International Conference on Computer Vision*, 2023.
- [10] O. H. MILANI *et al.* : Automated classification of mid-palatal suture maturation stages from cbcts using an end-to-end deep learning framework. *Scientific Reports*, 15(1):18783, 2025.
- [11] Y. NASSER *et al.* : Discriminative regularized auto-encoder for early detection of knee osteoarthritis : Data from the osteoarthritis initiative. *IEEE Transactions on Medical Imaging*, 39(9):2976–2984, 2020.
- [12] Huy Hoang NGUYEN *et al.* : Semixup : in-and out-of-manifold regularization for deep semi-supervised knee osteoarthritis severity grading from plain radiographs. *IEEE Transactions on Medical Imaging*, 39(12):4346–4356, 2020.
- [13] A. SEKHRI *et al.* : Shifting focus : From global semantics to local prominent features in swin-transformer for knee osteoarthritis severity assessment. In *2024 32nd EUSIPCO*, pages 1686–1690, Lyon, France, 2024.
- [14] Aymen SEKHRI *et al.* : Automatic diagnosis of knee osteoarthritis severity using swin transformer. In *Proceedings of the 20th International Conference on Content-Based Multimedia Indexing*, 2023.
- [15] A. TIULPIN *et al.* : Automatic knee osteoarthritis diagnosis from plain radiographs : A deep learning-based approach. *Scientific Reports*, 2018.
- [16] Aleksei TIULPIN et Simo SAARAKKALA : Automatic grading of individual knee osteoarthritis features in plain radiographs using deep convolutional neural networks. *Diagnostics*, 10(11):932, 2020.
- [17] Marouane TLIBA *et al.* : Deep-based quality assessment of medical images through domain adaptation. In *2022 IEEE International Conference on Image Processing (ICIP)*, pages 3692–3696, 2022.
- [18] Marouane TLIBA *et al.* : Satsal : A multi-level self-attention based architecture for visual saliency prediction. *IEEE Access*, 10:20701–20713, 2022.
- [19] Marouane TLIBA *et al.* : Pcqa-graphpoint : Efficient deep-based graph metric for point cloud quality assessment. In *ICASSP 2023 - 2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pages 1–5, 2023.
- [20] Yue WANG *et al.* : Dynamic graph cnn for learning on point clouds. *ACM Transactions on Graphics (TOG)*, 38(5):1–12, 2019.
- [21] Zhe WANG *et al.* : Siamese-gap network for early detection of knee osteoarthritis. In *2022 IEEE 19th International Symposium on Biomedical Imaging (ISBI)*, pages 1–4, 2022.
- [22] Zhe WANG *et al.* : Key-exchange convolutional auto-encoder for data augmentation in early knee osteoarthritis classification, 2023. arXiv :2302.13336.
- [23] Zhe WANG *et al.* : Temporal evolution of knee osteoarthritis : A diffusion-based morphing model for x-ray medical image synthesis, 2024. arXiv :2408.00891.
- [24] Zhe WANG *et al.* : Transformer with selective shuffled position embedding and key-patch exchange strategy for early detection of knee osteoarthritis. *Expert Systems with Applications*, 255:124614, 2024.