

**UNIVERSIDADE METODISTA DE PIRACICABA**

**PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS DO  
MOVIMENTO HUMANO**

Desenvolvimento e aplicação de rede neural convolucional para o  
diagnóstico de osteoartrite de joelho

Luís Felipe Sílio

2022

TESE DE DOUTORADO

LUÍS FELIPE SILIO

**DESENVOLVIMENTO E APLICAÇÃO  
DE REDE NEURAL CONVOLUCIONAL PARA O  
DIAGNÓSTICO DE OSTEOARTRITE DE JOELHO**

Tese apresentada ao Programa de Pós-Graduação em Ciências do Movimento Humano, da Universidade Metodista de Piracicaba, para o Título de Doutor em Ciências do Movimento Humano.

Orientador: Prof. Dr. Guanis de Barros Vilela Junior

**PIRACICABA**

**2022**

Ficha Catalográfica elaborada pelo Sistema de Bibliotecas da UNIMEP  
Bibliotecária: Joyce Rodrigues de Freitas - CRB-8/10115.

L732d	<p>Silio, Luís Felipe</p> <p>Desenvolvimento e aplicação de rede neural convolucional parao diagnóstico de osteoartrite de joelho / Luís Felipe Silio- 2022. 70f. ; 30 cm.</p> <p>Orientador: Prof. Dr. Guanís de Barros Vilela Junior.</p> <p>Tese (Doutorado) – Universidade Metodista de Piracicaba, Ciências do Movimento Humano, Piracicaba, 2022.</p> <p>Aprendizado de maquina. 2. Redes Neurais. 3. Osteoartrite. Silio, Luís Felipe. II. Título.</p> <p>CDD – 153</p>
-------	--

## RESUMO

**INTRODUÇÃO:** A osteoartrite do joelho (OA) é uma doença articular degenerativa, que ocasiona desgaste e perda progressiva da cartilagem local. Os sintomas de OA incluem rigidez, mobilidade articular limitada e presença de dor que podem levar a uma diminuição no tempo de atividade física diária, na qualidade de vida e comprometimento da saúde. Sua interpretação é, usualmente, realizada por meio de análise clínica de imagens o que implica em um trabalho cada vez maior nos centros ortopédicos e de radiologia. O presente estudo desenvolveu e aplicou o desempenho de uma rede neural convolucional projetada para auxiliar ortopedistas e radiologistas na detecção e classificação de osteoartrite do joelho de graus iniciais a severos, de acordo com o sistema de classificação Kellgren-Lawrence (KL). **OBJETIVO:** Desenvolver e validar uma Rede Convolucional Neural (CNN) capaz de classificar e diagnosticar a OA no joelho de forma dinâmica e eficaz. **MATERIAIS E MÉTODOS:** Utilizou-se uma pesquisa descritiva de caráter quali quantitativo e métodos da inteligência artificial (IA) aplicados na análise do movimento humano. Foi utilizado um banco de dados com radiografias de OA de joelho (Grau 0 - 3.085 imagens, Grau 1 - 1.416 imagens, Grau 2 - 2.062 imagens, Grau 3 - 1.029 imagens e Grau 4 - 236 imagens). Para análise e classificação das imagens foi utilizado um ambiente de desenvolvimento da linguagem *Python*, por meio da aplicação *Google Colab* executada em ambiente virtual (na nuvem). As imagens foram utilizadas para treinar um conjunto de arquiteturas de rede neural para a previsão do nível de gravidade, segundo a classificação de KL em OA. **RESULTADOS:** Após a configuração da CNN, iniciou-se o treinamento de máquina com as radiografias, em seguida realizados testes e por fim a integração, obtendo-se uma classificação expressa com as taxas de sensibilidade de teste conforme a densidade de rede com joelho saudável, OA leve, moderado e grave. Após a classificação e análise das imagens na rede convolucional, foi gerado o comportamento do classificador sobre a precisão do algoritmo na exatidão do diagnóstico. O algoritmo apresentou acurácia de 0,85 (OA mínimo), 0,79 (joelho saudável), 0,89 (OA moderado) e 0,98 (OA severo). Precisão de 0,67 (joelho saudável), 0,71 (OA mínimo), 0,86 (OA moderado) e 0,82 (OA severo). Sensibilidade de 0,65 (joelho saudável), 0,77 (OA mínimo), 0,79 (OA moderado) e 0,93 (OA severo). Especificidade de 0,86 (joelho saudável), 0,88 (OA mínimo), 0,94 (OA moderado) e 0,93 (OA severo). Todos os valores do FMI ficaram entre 0,94 e 1,00. **CONCLUSÃO:** Nosso modelo de aprendizagem profunda propostos, forneceram alta precisão e acurácia, satisfatórias para a detecção e classificação de osteoartrite leve ao severo do joelho em radiografias simples. Esse modelo poderá ser aplicado como auxílio no diagnóstico clínico de radiografias de joelho e na orientação do tratamento em cada estágio da patologia para médicos, radiologistas e profissionais do movimento humano.

**Palavras-chave:** Aprendizado de máquina; Redes neurais; Osteoartrite

## ABSTRACT

**INTRODUCTION:** knee osteoarthritis (OA) is a degenerative joint disease that causes wear and tear and progressive loss of the local cartilage. The symptoms of OA include stiffness, limited joint mobility and the presence of pain that can lead to a decrease in daily physical activity time, quality of life and health impairment. Its interpretation is usually carried out through clinical image analysis, which implies an increasing amount of work in orthopedic and radiology centers. The present study developed and applied the performance of a convolutional neural network designed to assist orthopedists and radiologists in the detection and classification of knee osteoarthritis from initial to severe grades, according to the Kellgren-Lawrence (KL) classification system. **OBJECTIVE:** To develop and validate a Convolutional Neural Network (CNN) capable of dynamically and effectively classifying and diagnosing knee OA. **MATERIALS AND METHODS:** A qualitative and quantitative descriptive research and artificial intelligence (AI) methods applied in the analysis of human movement were used. A database with knee OA radiographs was used (Grade 0 - 3,085 images, Grade 1 - 1,416 images, Grade 2 - 2,062 images, Grade 3 - 1,029 images and Grade 4 - 236 images). For analysis and classification of images, a Python language development environment was used, through the Google Colab application running in a virtual environment (in the cloud). The images were used to train a set of neural network architectures to predict the level of severity, according to the classification of KL in OA. **RESULTS:** after configuring the CNN, machine training was started with the radiographs, then tests were carried out and finally the integration, obtaining an express classification with the test sensitivity rates according to the network density with a healthy knee, mild, moderate, and severe OA. After the classification and analysis of the images in the convolutional network, the behavior of the classifier on the accuracy of the algorithm in the accuracy of the diagnosis was generated. The algorithm presented an accuracy of 0.85 (minimum OA), 0.79 (healthy knee), 0.89 (moderate OA) and 0.98 (severe OA). Accuracy of 0.67 (healthy knee), 0.71 (Minimal OA), 0.86 (moderate OA) and 0.82 (severe OA). Sensitivity of 0.65 (healthy knee), 0.77 (minimal OA), 0.79 (moderate OA) and 0.93 (Severe OA) Specificity of 0.86 (healthy knee), 0.88 (minimal OA), 0.94 (moderate OA) and 0.93 (severe OA). All FMI values were between 0.94 and 1.00. **CONCLUSION:** Our proposed deep learning model provided satisfactory high precision and accuracy for the detection and classification of mild to severe osteoarthritis of the knee on plain radiographs. This model can be applied as an aid in the clinical diagnosis of knee radiographs and in guiding treatment at each stage of the pathology for physicians, radiologists, and human movement professionals.

**Keywords:** Machine learning; Neural networks; osteoarthritis

# SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>9</b>
<b>2</b>	<b>Justificativa</b>	<b>13</b>
<b>3</b>	<b>Objetivos</b>	<b>14</b>
3.1	Objetivo Geral	14
3.2	Objetivos Específicos	14
<b>4</b>	<b>REVISÃO DE LITERATURA</b>	<b>15</b>
4.1	Etiologia da osteoartrite de joelho	16
4.2	Fisiopatologia da osteoartrite de joelho	16
4.3	Diagnóstico da osteoartrite de joelho	22
4.4	Aplicação da inteligência artificial no diagnóstico da osteoartrite	25
4.5	Rede neural convolucional e classificadores	29
4.6	Métricas e classificadores	31
<b>5</b>	<b>MATERIAIS E MÉTODOS:</b>	<b>35</b>
5.1	Características da amostra	36
5.2	DATASET- Conjunto de dados com radiografias simples	38
5.3	Importando Bibliotecas	39
5.4	Pré-processamento de imagens	40
5.5	O algoritmo para a estimativa de gravidade da osteoartrite do joelho	40
5.5.1	<b>Passo 1: algoritmo de localização da articulação do joelho</b>	<b>41</b>
5.5.2	<b>Passo 2: Classificação de gravidade da OA multi-entrada</b>	<b>42</b>
5.5.3	<b>Passo 3: Fase de treinamento e validação do algoritmo</b>	<b>43</b>
<b>6</b>	<b>RESULTADOS E DISCUSSÃO</b>	<b>44</b>
<b>7</b>	<b>CONSIDERAÇÕES FINAIS</b>	<b>56</b>
<b>8</b>	<b>REFERÊNCIAS</b>	<b>59</b>
<b>8</b>	<b>ANEXOS</b>	<b>70</b>

## LISTA DE FIGURAS

<b>Figura 1.</b> Exemplos de imagens radiográficas classificadas seguindo critérios descritos por Kellgren–Lawrence (KL).....	24
<b>Figura 2.</b> Categoria da CNN.....	26
<b>Figura 3.</b> Exemplo de arquitetura de rede neural com aplicação das camadas de filtros.....	30
<b>Figura 4.</b> Matriz de Confusão 2X2.....	32
<b>Figura 5.</b> Fluxograma das diferentes etapas envolvidas no desenvolvimento do trabalho.....	36
<b>Figura 6.</b> Imagem com marcações nos espaçamentos articulares.....	37
<b>Figura 7.</b> Arquitetura DenseNet. As redes neurais convolucionais profundas são compostas por uma sequência de conjuntos de filtros convolucionais com parâmetros treinados a partir dos dados. KL = Kellgren-Lawrence.....	38
<b>Figura 8.</b> Filtros de tom cinza no diagnóstico da OA de joelho.....	42
<b>Figura 9.</b> Treinamento e validação das épocas. Gráfico reportando a fase de treinamento e validação ao longo das épocas/fases do processamento.....	43
<b>Figura 10.</b> Exemplo de filtro para leitura das características da KL.....	45
<b>Figura 11.</b> Mapas de saliência.....	46
<b>Figura 12.</b> Matriz de Confusão.....	47

## LISTA DE ABREVIATURAS E SIGLAS

OAJ	Osteoartrite de Joelho
OA	Osteoartrite
KL	Kellgren & Lawrence
DL	Deep Learning
IA	Inteligência Artificial
CNN	Rede Neural Convolucional
MEC	Matriz Extracelular
MPP	Metaloproteinase
ADAMTS	Metaloproteinase com Motivos de Trombospondina
ACR	American College of Rheumatology
KOGS	Sistema de Classificação de Osteoartrite do Joelho
OMS	Organização Mundial da Saúde
ML	aprendizado de máquina tradicional
FMI	Índice Fowlkes-Mallows
AR	Artrite inflamatória
VP	Verdadeiro Positivo
VN	Verdadeiro Negativo
FP	Falso Positivo
FN	Falso Negativo
IKDC	International Knee Documentation Committee
ICC	Intervalo de Confiança
MCC	Coeficiente de Correlação de Matthews
EA	Estreitamento do Espaço Articular
OAI	Osteoarthritis Initiative
RNN	Rede Neural Recorrente

## **1 INTRODUÇÃO**

Com o envelhecimento da população e o aumento da prevalência de obesidade em todo o mundo, os números da osteoartrite de joelho (OAJ) são maiores em comparação com outros tipos de patologias ósseas (CHEN, 2018). A doença articular degenerativa osteoartrítica é uma das principais causas de deficiências crônicas no mundo. Os sintomas da OA incluem rigidez, função articular limitada e dor que levam a uma diminuição da quantidade de tempo de realização de atividade física diária e isso acarreta uma redução da percepção da qualidade de vida. A OAJ afeta principalmente as articulações de sustentação do corpo, sendo as articulações do joelho e do quadril os locais mais comuns (SASEK, 2015).

Os critérios diagnósticos da OAJ de joelho consistem em uma combinação da presença de dor, achados clínicos e radiológicos. Porém, a análise da dor, torna-se subjetiva, não sendo totalmente confiável numa visão técnica. A utilização de radiografias, ou exames por imagem, pode ser associada aos relatos clínicos, mas ainda é considerada subjetiva na acurácia do diagnóstico (CHEN, 2018; CHU; MILLIS; OLSON, 2014). A utilização de ressonância magnética tem evidenciado novos avanços, porém a grande maioria dos médicos ortopedistas fazem uso de radiografias para o diagnóstico da OAJ (ERICKSON et al., 2017).

A classificação OAJ de Kellgren & Lawrence (KL) é um sistema de classificação amplamente utilizado (KELLGREN; LAWRENCE, 1957a). Ao avaliar o espaçamento articular, formações osteofíticas, esclerose subcondral e, em sequência, graduar a gravidade de 0 a 4, os radiologistas seriam capazes de identificar a gravidade da doença, o que poderia sugerir ao cirurgião qual caminho a ser tomado quanto a

recuperação do indivíduo. Então, nessa linha de pensamento, melhorar a precisão/acurácia, diagnóstico e aplicabilidade, poderá alterar o direcionamento e qualidade no tratamento dos pacientes com quadro patológico.

Nos últimos anos, avanços na área de tecnologia vem sendo aplicado a grande área da saúde, em específico na análise de imagens radiológicas, a *Deep Learning* (DL) ou Aprendizagem de Máquina na Inteligência Artificial (IA) vem mostrando resultados significativos no diagnóstico e detecção da OAJ de joelho, bem como, sua classificação com base no sistema de graduação KL (KOHN; SASSOON; FERNANDO, 2016; SWIECICKI et al., 2021).

Entretanto, o aprendizado de máquina tradicional causa uma sobrecarga para extrair recursos antes de treinar os algoritmos. Com a Rede Neural Convolutacional (CNN), por outro lado, alimentamos os dados diretamente no algoritmo e permitimos que ele aprenda diferentes recursos (PASSOS, R. P., & JUNIOR, 2018).

Atualmente, existem poucos artigos científicos publicados sobre a aplicação da CNN para classificação da OAJ de joelho (CHEN et al., 2019; LIU; LUO; HUANG, 2020; OLSSON et al., 2021; SHEN; WU; SUK, 2017; SWIECICKI et al., 2021; TIULPIN et al., 2018a).

Atualmente, é a radiografia simples o procedimento mais utilizado para o diagnóstico da OAJ, sendo necessário exame clínico de rotina da articulação com característica sintomática, sendo segura e com baixo custo. Mesmo apresentando essas vantagens, o método com radiografia simples é questionável na tentativa de detectar alterações precoces da OAJ (TIULPIN et al., 2018b). Esta afirmação pode ser explicada por diversos fatores, primeiro, uma característica marcante da OAJ é a progressão da degeneração e desgaste da cartilagem articular, sendo um tecido que

não pode ser visto diretamente na radiografia simples. Em segundo, não obstante, a avaliação das alterações na articulação apresenta ser um problema tridimensional, o método de imagem utiliza-se apenas projeção de soma bidimensional.

Deste modo, a interpretação da imagem resultante propõe um profissional com expertise. Possivelmente, em função do pressuposto, o diagnóstico precoce da OAJ torna-se difícil na prática clínica e nas aplicações diretas com os pacientes com quadro patológico (KELLGREN; LAWRENCE, 1957b; TIULPIN et al., 2018b).

Além das limitações da radiografia simples apontadas acima, o diagnóstico da osteoartrite depende muito da subjetividade dos especialistas, pois não há um sistema de categorização estritamente definido.

A escala de classificação KL (KELLGREN; LAWRENCE, 1957b) comumente usada é semiquantitativa e ambígua, como mostrado por diversas pesquisas que discordam (Kappa 0,566, 0,667, 0,67) (CULVENOR et al., 2015; GOSSEC et al., 2008; SHEEHY et al., 2015). Esta dúvida entre os especialistas dificulta muito o diagnóstico precoce da osteoartrite, podendo afetar milhões de pessoas em todo o mundo. No entanto, acredita-se que o diagnóstico assistido por computador, a IA poderá ser usada como uma ferramenta precisa para auxiliar os clínicos em suas decisões.

Ademais, a precisão diagnóstica desses métodos em situações específicas superam os especialistas humanos; assim, eventualmente, os pacientes receberão diagnósticos mais precisos e confiáveis. Por último, adicionando a cadeia diagnóstica com esses métodos, radiologistas e outros especialistas clínicos, como profissionais de educação física, fisioterapeutas, fisiologistas, ortopedistas, entre outros profissionais, podem se concentrar menos em tarefas rotineiras, como classificação de imagens, e se concentrar mais em intervenções na linha da reabilitação.

Por todos os motivos mencionados, acredita-se que o diagnóstico de osteoartrite de joelho por radiografia simples pode ser melhorado significativamente com o uso de métodos baseados em aprendizado de máquina combinados com avaliação clínica. Dada a grande importância e relevância do tema, o objetivo deste trabalho foi desenvolver e aplicar a CNN, que por sua vez fará a classificação de doenças para o diagnóstico de OAJ de forma dinâmica, eficaz, com acurácia e precisão superiores às realizadas pelo ser humano.

## 2 JUSTIFICATIVA

A prevalência da osteoartrite do joelho está aumentando no Brasil e no mundo, em consequência ao aumento da idade associado a obesidade e estilo de vida. Ademais, este problema de saúde pública, tem levado a uma crescente demanda de artroplastias de joelho, ou procedimentos cirúrgicos nesta articulação em específico (OLSSON et al., 2021). A maioria dos cirurgiões ortopédicos/ ortopedistas utilizam radiografias simples do joelho com suporte ao diagnóstico da osteoartrite. Melhorar a confiabilidade e a reprodutibilidade dessas interpretações poderia, portanto, ser extremamente benéfico. Pesquisadores aplicaram algoritmos de aprendizado de máquina simples e aprendizado profundo para a detecção e classificação da OA de joelho, sendo desenvolvido, por exemplo, um algoritmo de aprendizado de máquina baseado na classificação de KL para detectar a OAJ de joelho precoce, atingindo uma taxa de acurácia de aproximadamente 83% com seu modelo usando 1024 imagens de raios-X do joelho (BRAHIM et al., 2019). Outras pesquisas aplicaram uma rede CNN para classificar automaticamente a gravidade da OAJ de joelho com base na classificação KL. Seu modelo referenciou como base, os lados medial e lateral da articulação do joelho, com uma rede convolucional aplicada em cada lado, resultando numa acurácia multiclass de 66,7% (TIULPIN et al., 2018; PONGSAKONPRUTTIKUL et al., 2022).

Neste sentido, o diagnóstico correto e eficiente, em conjunto com a classificação de uma OAJ são, portanto, de grande interesse no acompanhamento e planejamento para tratamento conservador ou cirúrgico da população.

### **3 OBJETIVOS**

#### **3.1 OBJETIVO GERAL**

Desenvolver e validar uma CNN capaz de classificar e diagnosticar a OAJ do joelho de forma dinâmica e eficaz.

#### **3.2 OBJETIVOS ESPECÍFICOS**

- Desenvolver e treinar o modelo de algoritmo;
- Mensurar a acurácia, precisão, sensibilidade, especificidade, FMI, Índice Youden e MCC da CNN no diagnóstico da osteoartrite.
- Aplicar uma CNN no diagnóstico da osteoartrite;

#### **HIPÓTESES DA PESQUISA**

Através da utilização da CNN, haverá uma otimização do tempo, eficiência e confiabilidade no diagnóstico do grau de lesão na osteoartrite de joelho, quando comparado ao método de avaliação padronizado internacionalmente.

## 4 REVISÃO DE LITERATURA

### 4.1 Etiologia da osteoartrite de joelho

A incidência e prevalência da osteoartrite (OA) dependem da definição utilizada, como sintomática, radiográfica ou diagnosticada pelo médico. Pode ser descrita patologicamente, radiograficamente ou clinicamente. Deve-se notar que nem todas com OA radiográfica são sintomáticas. Devido às várias definições de OA usadas, as taxas de prevalência e incidência relatadas variam entre os estudos. Em geral, as estimativas de prevalência para OA sintomática tendem a ser menores do que a OA radiográfica, pois sua presença é definida por uma combinação de sintomas como dor e rigidez, além de características radiográficas (VINA ER *et al.*, 2018)

A prevalência padronizada por idade de OA de joelho confirmada radiograficamente sintomática foi estimada em 3,8% globalmente, com taxas sendo mais altas em mulheres (4,8%) em comparação com homens (2,8%) (CROSS M *et al.*, 2014).

Quatorze milhões de pessoas nos Estados Unidos têm OAJ sintomática, sendo mais da metade com idade inferior a 65 anos. (VINA ER *et al.*, 2018).

Estudos incluindo populações asiáticas relatam um alto índice de estimativas de prevalência para OA de joelho. Dados coreanos relatam uma prevalência de 4,5% para homens e 19% para mulheres (PARK JH *et al.*, 2017).

Uma revisão sistemática de dados chineses relativos a essa patologia descobriu que a prevalência de OA sintomática do joelho aumentou com a idade (3,1%) na faixa etária de 15 a 39 anos, em comparação com 26,3%, naqueles com mais de 70 anos de idade (LI D *et al.*, 2020). A prevalência de OA de joelho sintomática também foi maior em mulheres (19,1%), em comparação com os homens (10,9%).

Estudos aplicados em áreas rurais e urbanas na Índia relatam maior prevalência em áreas rurais, com prevalência de dor no joelho de 13% e 8% nas áreas rurais e urbanas, respectivamente. Homens com mais de 60 anos em áreas rurais da China relataram duas vezes a taxa de dor sintomática no joelho em comparação com aqueles residentes em áreas urbanas.

Taxas mais altas nas áreas rurais podem ser resultado da carga de trabalho, estado nutricional, longevidade, menor escolaridade e pior situação socioeconômica. Além disso, maiores taxas de incidência de OA de joelho foram encontradas em áreas consideradas mais carentes por medidas de status socioeconômico, inclusive entre aquelas com níveis mais baixos de educação (CALLAHAN LF et al., 2020).

#### **4.2 Fisiopatologia da osteoartrite de joelho**

No passado, a osteoartrite era considerada simplesmente um processo degenerativo de "desgaste" e, portanto, muitas vezes chamada erroneamente de doença articular degenerativa. No entanto, a patogênese da OA é muito mais complexa do que apenas o desgaste e o termo "osteoartrite", onde "-itis" é indicativo de um processo inflamatório, está de fato correto (LANE NE et al., 2011). Há uma variedade de fatores que desempenham um papel importante na patogênese da OA, incluindo fatores biomecânicos, mediadores pró-inflamatórios e proteases. Ao compreender os mecanismos que conduzem à destruição do tecido articular na OA e identificar os principais fatores envolvidos, estão surgindo novos alvos para a terapia que irão além do alívio sintomático para retardar ou interromper a progressão da OA (HUANG Z et al., 2018).

O termo artrite é utilizado para definir inflamação das articulações, e pode se referir a mais de cem patologias reumáticas e condições que afetam as articulações e tecidos adjacentes as articulações. Neste grupo, a osteoartrite também conhecida como doença articular degenerativa, OA primária, artrite de desgaste ou artrite relacionada à idade, é uma das doenças articulares inflamatórias mais prevalentes e afeta 250 milhões de pessoas no mundo (MORA; PRZKORA; CRUZ-ALMEIDA, 2018).

A AO pode acometer pequenas, médias e grandes articulações, entretanto o joelho é a articulação mais frequentemente afetada. A osteoartrite de joelho está relacionada a quadros de dor crônica persistente, representando uma das principais queixas na terceira idade (JANG; LEE; JU, 2021).

Inicialmente, acreditava-se que a OA era uma doença exclusivamente degenerativa da cartilagem, no entanto, evidências mais recentes provaram que a OA é uma condição multifatorial. Entretanto sabe-se que lesões articulares e carga excessiva aceleram a degeneração articular (CHU et al., 2014).

Pacientes afetados pela condição devem reduzir atividades que sobrecarreguem a articulação afetada e realizar intervenções de reabilitação, que incluem fisioterapia e para uma melhora no estilo de vida, com o intuito de prolongar a saúde das articulações e reduzir a incidência de dor (O'NEILL; FELSON, 2018)

Apesar da gravidade, os tratamentos disponíveis para a AO não produziram resultados eficientes para modificar a doença em estágios avançados. As estratégias terapêuticas utilizadas atualmente se baseiam em palição para diminuir a velocidade de progressão da doença, até que a substituição articular seja indicada, e por este motivo a osteoartrite continua sendo uma das causas mais frequente de incapacidade (CHU et al., 2014).

O joelho é a maior e mais complexa articulação sinovial em humanos e consiste na relação de três estruturas ósseas: região distal do fêmur, tíbia proximal e patela; que se mantêm unidos através ligamentos. Entretanto, para que não haja desgaste, as extremidades dos ossos que a compõem, estão cobertas por cartilagens (cartilagem meniscal e cartilagem livre) e envoltos por uma membrana sinovial (MORA; PRZKORA; CRUZ-ALMEIDA, 2018).

Este último é responsável por produzir o líquido sinovial, componente que lubrifica e fornece nutrientes para a cartilagem, que é um tecido avascular.

Infelizmente, devido o uso constante e estresse ao qual é submetida, essa articulação é um local frequente para condições dolorosas, incluindo AO. Estima-se que, cerca de 30% dos indivíduos com mais de 45 anos têm evidência radiográfica de OA de joelho, destes, quase 50% apresentam sintomas, principalmente dor ao movimento (KATZ; ARANT; LOESER, 2021).

A OA pode ser classificada em dois grupos, de acordo com sua etiologia: primária, de causa idiopática ou não traumática; e secundária, devido a trauma ou desalinhamento mecânico (MORA et al., 2018).

OA é uma patologia multifatorial, cuja etiologia está relacionada a fatores biomecânicos, como traumas ou forças mecânicas, processos inflamatórios, além de distúrbios bioquímicos e metabólicos. Clinicamente, as características clássicas observadas em radiografias, incluem estreitamento do espaço articular devido a perda da cartilagem articular e do menisco, além de alterações ósseas, incluindo esclerose do osso subcondral e osteófitos (MORA; PRZKORA; CRUZ-ALMEIDA, 2018).

Inicialmente, a OA era definida como uma patologia degenerativa da cartilagem; entretanto as últimas evidências demonstram que há o comprometimento

de cartilagem, osso subcondral, músculos periarticulares, ligamentos e sinóvia. Clinicamente, os achados radiográficos corroboram com a teoria de que o comprometimento é de todas as estruturas articulares. Biomecanicamente e fisiologicamente também seria impossível restringir o quadro exclusivamente à cartilagem, considerando que este tecido é avascular e não tem inervação, sendo incapaz de produzir inflamação ou dor; parece lógico que as fontes da dor são componentes não cartilaginosos do complexo articular (MACCHI et al., 2018).

A cartilagem é um tecido conjuntivo, formado condrócitos - células que compõem o tecido cartilaginoso e que tem a função de regular sua composição metabólica – embutidos em uma Matriz Extracelular (MEC). Cerca de 70% dessa matriz é composta de água e os 30% restantes de substâncias orgânicas, principalmente colágeno do tipo II, agrecano 1 e outros proteoglicanos (BELLUZZI et al., 2020).

Geralmente, os condrócitos mantêm os componentes da MEC em condições normais e neste caso as substâncias orgânicas estão em baixo volume (JANG; LEE; JU, 2021).

Em situações fisiológicas, os condrócitos de cartilagem adulta saudável são mantidos quiescentes (estado de repouso) na maior parte do tempo, uma vez que o tempo de meia-vida do colágeno tipo II é de cerca de 120 anos, enquanto do agrecano de 120 dias, exigindo pouquíssima atividade metabólica por parte deste conjunto celular. Além disso, para proteger os receptores dos condrócitos da interação com alguns componentes da MEC e garantir a estabilidade dessas células, a matriz

pericelular possui uma composição única. As redes contendo colágeno Tipo II também são preservadas e geralmente não são degradadas, pois são revestidas por proteoglicanos, principalmente o agrecano.

Os condrócitos, portanto, se encontram praticamente isolados e vivem em situação de hipoxia, protegidos por uma rede de colágeno e em um ambiente avascular. Entretanto, qualquer alteração na composição do MEC ou situações de estresse podem ser detectados por essas células, que deixam de ser quiescentes. Neste caso, geralmente em resposta à estimulação mecânica ou inflamatória, os condrócitos sofrem uma alteração fenotípica e tornam-se ativos, mudança caracterizada pela proliferação celular e formação de clusters. Diante da ativação dos condrócitos, é iniciado um feedback positivo e conseqüentemente existe o aumento da síntese de agrecano, colagenase e de enzimas degradadoras que diminuem o pH da matriz cartilaginosa (JANG; LEE; JU, 2021).

As principais enzimas degradadoras presentes em situações patológicas, são as enzimas proteolíticas e as agrecanases. Como enzimas proteolíticas, as mais abundantes são as metaloproteinases (MMPs), que incluem as colagenases MMP-1 e MMP-13, que são altamente eficientes contra o colágeno tipo II; a MMP-3, uma potente agrecanase; e o ativador de MMP. Por outro lado, as agracanases mais frequentes são a disintegrina e Metaloproteinase com Motivos de Trombospondina (ADAMTS) (KATZ; ARANT; LOESER, 2021).

A inibição de enzimas agrecanases, e conseqüentemente da depleção de proteoglicanos, já foi atribuída a redução da progressão da AO; entretanto não conseguem parar a hipertrofia dos condrócitos que seguem em atividade. Da mesma forma, a inibição das colagenases também não são suficientes para impedir o

agravamento da doença, uma vez que após o início, a degradação das redes de colágeno é irreversível. No entanto, apesar da importância da depleção dos proteoglicanos e das redes de colágenos no processo patológico da AO, esses eventos isolados não são suficientes para impulsionar a erosão da cartilagem (FARAH et al., 2022).

Ao que parece, a ativação dos condrócitos e a inflamação são os principais eventos que levam à degradação da cartilagem e podem causar OA. Já está comprovado que a prostaglandina E2, um mediador lipídico relacionado a vasodilatação no processo inflamatório, é um dos principais fatores catabólicos associados à OA, onde a MMP é crucial para a degeneração da cartilagem. Assim, essa enzima representa um potencial alvo terapêutico na OA.

Logo, é possível prever que na OA, o remodelamento do osso subcondral é desencadeado, em maior parte, pelo desenvolvimento de vasos sanguíneos nos canais vasculares, que contêm osteoblastos e nervos sensoriais. Os canais vasculares são importantes para a comunicação bioquímica entre osso e cartilagem, portanto ambas as estruturas são afetadas na OA.

Perpetuando o ciclo vicioso de degradação da cartilagem, em resposta as múltiplas mudanças desencadeadas, os condrócitos expressam citocinas, quimiocinas, alarminas, padrão molecular associado a danos e adipocinas. Todos esses mediadores vão atuar como fatores parácrinos e irão atingir o líquido sinovial e desencadear um processo inflamatório com a produção de macrófagos sinoviais e fibroblastos (JANG; LEE; JU, 2021).

Sendo assim, considerando todos os mecanismos compreendidos até o momento, pode-se afirmar que a dor relacionada a AO é consequência das alterações

bioquímicas e estruturais. Uma vez que os canais vasculares têm terminações nervosas sensoriais e que a cartilagem articular apresenta inervação própria, estímulos nessas regiões podem contribuir para a dor tibiofemoral (HOUARD; GOLDRING; BERENBAUM, 2013).

### **4.3 Diagnóstico da osteoartrite de joelho**

As características clássicas da OAJ observadas em radiografias são: estreitamento do espaço articular, devido a perda da cartilagem articular e do menisco; e, alterações ósseas, incluindo esclerose do osso subcondral e osteófitos. Entretanto, essas características são visíveis em casos intermediários a graves; em estágios iniciais as alterações são minimamente visíveis em imagens radiográficas (JANG; LEE; JU, 2021).

Portanto, embora seja uma patologia frequente, o diagnóstico da OAJ continua sendo extremamente difícil. Nos dias atuais, os critérios de classificação do American College of Rheumatology (ACR) para OA do joelho tem o objetivo primário de diferenciar esta patologia de outras artrites, como por exemplo, artrite reumatoide e espondilite anquilosante (JANG et al., 2021).

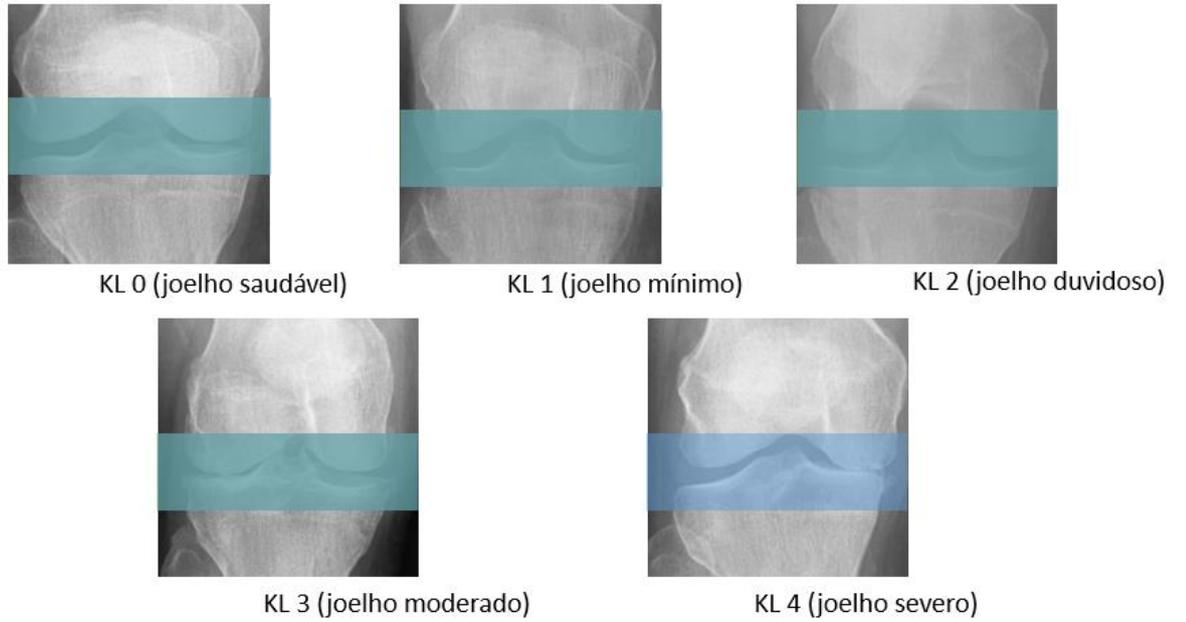
Posteriormente, após a realização do diagnóstico diferencial e da exclusão de outras artrites, a degeneração da cartilagem e outras alterações esqueléticas provenientes da AO, podem ser examinadas radiograficamente e quantificadas a fim de direcionar o tratamento e definir se a conduta será paliativa ou intervencionista.

Atualmente, pode ser usada a escala de classificação semiquantitativa como a classificação Ahlbäck, sistema de classificação de osteoartrite do joelho (KOGS) e sistema KL. Entretanto, a escala KL é mais utilizada universalmente, sendo proposta

por Kellgren e Lawrence, elaborada e testada em 1957 e posteriormente, em 1961, foi aceita pela Organização Mundial da Saúde (OMS) como definição radiológica de OAJ para fins de estudos epidemiológicos (HERNÁNDEZ-VAQUERO; FERNÁNDEZ-CARREIRA, 2012; JANG; LEE; JU, 2021; KELLGREN; LAWRENCE, 1957a; KNIPE; PAI, 2014).

A escala classifica o grau de comprometimento articular com base nas alterações radiográficas observadas. Originalmente, de acordo com essa classificação, o comprometimento pode ser classificado de 0 a 4, sendo que o grau 0, trata-se de imagens radiográficas sem alterações patológicas de AO; o grau I, são imagens que demonstram estreitamento suspeito do espaço articular e presença de osteófitos na borda óssea; o grau II é classificado a partir de radiografias com possível estreitamento do espaço articular e osteófitos definidos; o grau III é caracterizado por estreitamento do espaço articular definido, presença de múltiplos osteófitos, alguma esclerose subcondral e possível deformidade do contorno ósseo; por último, o grau IV, refere-se a presença de notável estreitamento do espaço articular, severa esclerose subcondral, deformidades do contorno ósseo e grande presença de osteófitos. Exemplos radiográficos seguindo a escala de KL são demonstradas na figura 1 (KELLGREN; LAWRENCE, 1957a).

**Figura 1.** Exemplos de imagens radiográficas classificadas seguindo critérios descritos por Kellgren–Lawrence (KL).



**Fonte:** (Adaptado de JANG et al., 2021).

#### **4.4 Aplicação da inteligência artificial no diagnóstico da osteoartrite**

Recentemente, o aprendizado profundo, que é uma forma de IA, vem apontando resultados promissores na interpretação de imagens radiográficas (LIND et al., 2021; OLSSON et al., 2021).

Estes últimos achados científicos apresentam resultados promissores na detecção da OA de joelho e na classificação de sua gravidade com base no sistema de graduação KL (SWIECICKI et al., 2021; TIULPIN et al., 2018a).

A tecnologia de aprendizado profundo tem sido amplamente aplicada a uma variedade de campos usando tecnologias avançadas de hardware e software. Entre eles, a rede neural convolucional (CNN) é uma tecnologia que é usada principalmente no campo da imagem. A CNN reconhece os padrões extraídos usando um filtro e os acumula repetidamente, de modo que mesmo padrões complexos podem ser reconhecidos (KRIZHEVSKY et al., 2012; LONG et al., 2015).

Dado que resultados robustos são obtidos independentemente da imagem, as limitações das técnicas de processamento de imagem existentes podem ser abordadas. Portanto, estudos baseados na aplicação da CNN em imagens médicas usando os recursos descritos anteriormente estão sendo continuamente relatados.

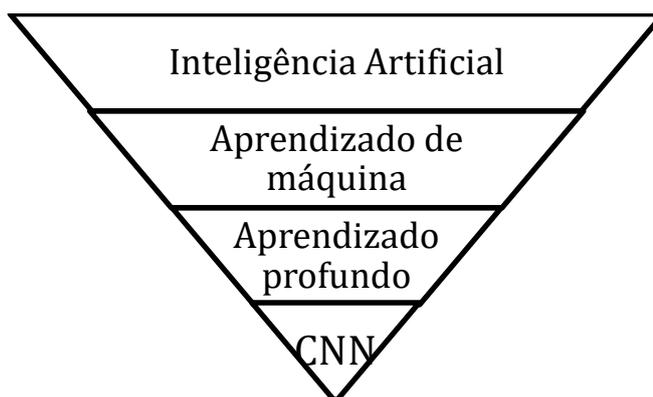
O aprendizado de máquina tradicional (Machine Learning, ML) geralmente trabalha na extração de recursos antes de treinar ou testar os algoritmos. Em contrapartida a CNN (CNNs - Convolutional Neural Networks), alimenta os dados diretamente no algoritmo, permitindo que o mesmo aprenda diferentes recursos na aprendizagem. Esta abordagem, abriu novos caminhos para não especialistas no campo a ML incorporarem e desenvolverem suas próprias pesquisas e aplicações,

como análise de imagens médicas, em específico radiografias (SHEN; WU; SUK, 2017).

Achados recentes utilizaram diferentes estratégias do uso IA e assumiram cada vez mais a importância do aprendizado profundo na área médica/hospitalar, incluindo o diagnóstico de OA de joelho monitorado por computador que objetiva diminuir os erros ou dúvidas humanas no diagnóstico (YEOH P et al., 2021; B. GUAN et al., 2020).

Uma instigação significativa no desenvolvimento da IA na pesquisa em OAJ é a disponibilidade de enormes repositórios de dados clínicos e de imagem, como por meio da Osteoarthritis Initiative (OAI) (ER GARWOOD, et al., 2020; YEOH P et al., 2021). Existem diferentes tipos de arquitetura de aprendizado profundo, como rede neural convolucional (CNN), rede neural recorrente (RNN), rede neural recursiva e rede pré-treinada não supervisionada ( YEOH P et al., 2021).

**Figura 2.** Categoria da CNN



**Fonte:** Adaptado de YEOH et al., 2021

Figura 2 apresenta a categoria da CNN sob o guarda-chuva da IA. A CNN é uma forma de aprendizado profundo na inteligência artificial (IA). As CNNs são

robustas com menor complexidade e com padrões de treinamento onde a rede aprende durante todo o processo de otimização com um número reduzido de parâmetros ( YEOH P et al., 2021; VILELA JUNIOR et al., 2022; PASSOS, R. P., & JUNIOR, 2018).

A CNN esta estruturada numa arquitetura geral que envolve uma camada de entrada, camadas ocultas associadas a uma série de filtros de imagem, com camadas de redes onde os filtros de imagem são projetados na imagem de entrada e camada de saída onde o recurso será extraído (YEOH P et al., 2021;VILELA JUNIOR et al., 2022; PASSOS, R. P., & JUNIOR, 2018).

No ambiente hospitalar, cada vez mais, observa-se escassez de radiologistas experientes com treinamento ortopédico, especialmente nas unidades básicas de saúde em uso da comunidade, ou em horários específicos de plantão (LIND et al., 2021; LINDSEY et al., 2018; WAITE et al., 2016).

A utilização de tomografia computadorizada pode melhorar a eficiência, porém a mesma não está disponível quanto às radiografias simples nas unidades básicas. Para mais, a interpretação de radiografias auxiliada por algoritmos inteligentes, pode ser útil tanto para ajudar os médicos a avaliar adequadamente o grau da osteoartrite, quanto para revisar uma grande quantidade de laudos para melhor intervenção junto a equipe multidisciplinar.

Atualmente, pesquisas recentes têm evidenciado resultados significativos e de grande impacto na aplicação e utilização do aprendizado profundo de máquina, redes neurais profundas na interpretação de imagens na área da saúde (ERICKSON et al., 2017; LIND et al., 2021; TING et al., 2017).

Em específico, na medicina, nos últimos anos, a aplicação da inteligência artificial vem explorando especialidades na endocrinologia, em fotografias de retina, na oncologia para reconhecimento de nódulos pulmonares e na dermatologia, em análise de lesões cancerígenas (ESTEVA et al., 2017; HUA et al., 2015; KOOI et al., 2017).

Em específico, a osteoartrite de joelho é uma das patologias que mais agrava a incapacidade de idosos e jovens. Recentemente, pesquisas mostram que a OA da articulação do joelho influenciará a capacidade funcional de aproximadamente 130 milhões de pessoas até o ano de 2050, em conjunto com o envelhecimento da população global (MAIESE, 2016; WANG et al., 2021). Em levantamento nos números de gastos na saúde pública e privada, a OA de joelho contribui com mais de 20 bilhões de dólares gastos, e as opções de tratamento são limitadas nos graus mais avançados da patologia (WANG et al., 2021).

Desta forma, é de suma importância a avaliação e detecção da OAJ de forma precoce, para assim, diminuir o agravo da patologia e melhorar a qualidade de vida dos pacientes. Porém, fatores de risco, como: idade; sexo; sejam utilizados no diagnóstico da OAJ, as radiografias simples podem confirmar e diferenciar a patologia de outras manifestações de artrite ou doenças osteoarticulares.

A metodologia utilizada nos grandes centros urbanos, ou nos diferentes hospitais, capitais ou cidades menores, indicam grande custo ou inviabilidade de equipamentos, principalmente nos hospitais públicos.

Nos métodos utilizados habitualmente, incluem, imagens radiográficas simples (como raio-X), ultrassonografia e ressonância magnética. Em contrapartida, as radiografias simples apresentam como a modalidade com menor custo operacional, é

mais comum nos hospitais do que os outros métodos citados, sendo de grande utilidade na prática clínica (WANG et al., 2021; WENHAM; GRAINGER; CONAGHAN, 2014).

O impacto da utilização de IA na análise clínica pode levar para uma abordagem eficiente em quantitativo de tempo e custo, acelerando os ensaios clínicos, melhorando o processo de triagem dos pacientes com quadro grave da patologia. Na prática clínica, fazer uso de um método ou mecanismo consistente e automatizado para avaliar e realizar o diagnóstico de exames radiográficos sequenciais de pacientes permitiria um melhor rastreamento da progressão da doença, além da diminuição dos custos operacionais no sistema privado e público de saúde.

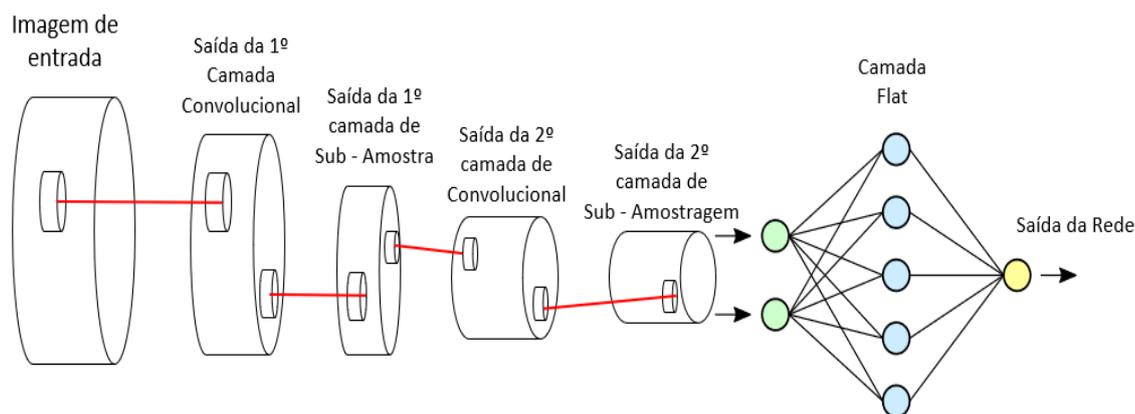
#### **4.5 Rede Neural convolucional e classificadores**

Atualmente, devido a globalização e avanços na tecnologia, muito tem se desenvolvido e discutido sobre Deep Learning (aprendizado de máquina) e Inteligência Artificial, sendo uma das áreas que de grande atenção na aprendizagem de algoritmos para análise de imagens ou figuras. Nessa linha de pesquisa e aplicação, um dos algoritmos utilizados para trabalho com imagens é a CNN (OLSSON et al., 2021; VILELA JUNIOR et al., 2022).

As Redes Neurais Convolucionais (CNNs - Convolutional Neural Networks) são exemplos de redes neurais organizadas para receber imagens como entrada. O computador ou rede recebe esta imagem e armazena como dados, em sequência, os valores são armazenados em uma matriz, mantendo as características espaciais de uma imagem, como a altura e largura, tonalidade de cores entre outras características (LIND et al., 2021).

A estrutura da rede neural desenvolve uma classificação de uma imagem, em específico, classifica uma imagem em relação à presença de outros objetos ou características, uma CNN tem um processo de extração de características da imagem, um *feature extractor* (técnicas de extração para reduzir a dimensionalidade de um conjunto de dados). Essa etapa de extração de características tem como principal finalidade a aplicação de filtros na imagem de entrada, assim determinando uma estrutura de filtros numa rede convolucional, conforme mostra a figura 3.

**Figura 3.** Exemplo de arquitetura de rede neural com aplicação das diferentes camadas de filtros



**Fonte:** Próprio autor

Um conceito importante no entendimento de uma CNN é o trabalho com volumes. Na Figura 3, é possível identificar que as camadas foram representadas por volumes. Uma imagem colorida pode ser caracterizada como volume, em que sua altura e largura correspondem à altura e à largura da imagem e sua profundidade

corresponde ao número de canais de cor dessa imagem. Em exemplo, uma imagem colorida, terá diversos canais, um para cada tom e cor diferente, em contrapartida, uma imagem preto e branco, terão diversos volumes ou camadas de diferentes tons de cinza. Ao aplicar os filtros, os mesmos devem ter profundidade igual ao que recebem como entrada. Quando aplicado uma CNN, soma-se os resultados de cada canal, resultando em um canal só, ou uma imagem filtrada com as diferentes características.

#### **4.6 Métricas e classificadores**

No desenvolvimento e aplicação de algoritmos de inteligência artificial é de extrema importância a utilização de métricas para aferição e testagem da eficiência dos mesmos, objetivando assim, uma maior segurança, principalmente na área da saúde e do movimento humano (VILELA JUNIOR et al., 2022).

Essas métricas são, usualmente, acurácia, precisão, sensibilidade, especificidade, dentre outras, em sequência um exemplo de cada métrica e sua utilização na interpretação dos dados

A metodologia utilizada para avaliar a qualidade de um classificador no chamado aprendizado de máquina (machine learning) são obtidas através da matriz de confusão. Para dados binários, onde existem apenas duas possibilidades para a classificação ser verdadeira (verdadeiro positivo e verdadeiro negativo) a matriz de confusão é exemplificada na Figura 4.

**Figura 4.** Matriz de Confusão 2X2

		<b>Predição</b>	
<b>Realidade</b>		<b>Verdadeiro Positivo (VP)</b>	<b>Falso Negativo (FN)</b>
		<b>Falso Positivo (FP)</b>	<b>Verdadeiro Negativo (VN)</b>

Fonte: VILELA JUNIOR et al., 2022)

### **Acurácia**

A questão que a acurácia busca responder é: qual o percentual de casos verdadeiros em relação a todos os resultados?

A acurácia foi calculada pela razão entre o número total de observações que o modelo acertou (VP+VN) e o número total de observações que o modelo previu (VP+VN+FP+FN) (VILELA JUNIOR et al., 2022).

$$Acurácia = \frac{VP + VN}{VP + VN + FP + FN}$$

### **Precisão**

A precisão busca responder à questão: Que percentagem de VPs prevista está correta? Trata-se da razão de VP em relação a todos os valores positivos classificados (VP+FP). Quando o número de FP é elevado a precisão diminui de maneira significativa (VILELA JUNIOR et al., 2022).

$$Precisão = \frac{VP}{VP + FP}$$

## **Sensibilidade**

Busca responder à questão: Qual a porcentagem de todos os VPs que foram previstos corretamente? Trata-se da razão entre os valores VP e (VP+FN).

É amplamente utilizada em situações em que os FN são potencialmente mais preocupantes que os FP. Mede a taxa de verdadeiros positivos que o modelo consegue prever, isso possibilita analisar a capacidade do classificador em identificar os FN (VILELA JUNIOR et al., 2022).

$$\text{Sensibilidade (retorno)} = \frac{VP}{VP + FN}$$

## **Especificidade**

A especificidade busca responder à questão: Qual a porcentagem de todos os valores negativos que foram previstos corretamente?

É uma métrica utilizada em um classificador que avalia a taxa de VN, pode ser calculada pela razão entre os valores VN e (VN+FP).

A especificidade não fornece necessariamente uma indicação precisa sobre um resultado negativo no teste de classificação porque os resultados negativos do teste podem conter muitos resultados falsos negativos. Neste contexto, um resultado negativo em um teste de triagem com alta especificidade não é útil para descartar definitivamente, por exemplo, a existência de artrite de joelho em uma pessoa em particular (VILELA JUNIOR et al., 2022).

$$\text{Especificidade} = \frac{VN}{VN + FP}$$

### **Índice Fowlkes-Mallows (FMI)**

O FMI é definida pela raiz quadrada do produto entre a sensibilidade e a precisão. Esse índice apresenta valores entre 0 e próximo de 1, sendo que valores mais próximos de 1 indicam maiores similaridades entre dois conjuntos de dados (VILELA JUNIOR et al., 2022).

$$FMI = \sqrt{\text{sensibilidade} \times \text{precisão}}$$

### **Coeficiente de Correlação de Matthews (MCC)**

O coeficiente de correlação de Matthews (MCC) é uma métrica mais robusta para aferir a eficiência de um algoritmo inteligente uma vez que este pode ser compreendido como uma síntese da ponderação do número de verdadeiros positivos, verdadeiros negativos, falsos positivos e falsos negativos. O MCC mede a correlação entre as classificações binárias observadas e previstas (CHICCO D, 2020; CHICCO D, 2021; VILELA JUNIOR et al., 2022).

É calculado pela equação:

$$MCC = \frac{TP \times TN - FP \times FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}}$$

### **Índice Youden (IY)**

O Índice Youden representa uma medição sumária da curva característica operacional do receptor (ROC) para a precisão de um teste de diagnóstico com pontos finais ordinais ou contínuos.

É originário do trabalho de Youden WJ. em 1950 e demonstra o peso igual a falsos valores positivos e falsos negativos, por isso pode-se concluir que quando dois testes têm o mesmo índice, significa que eles têm a mesma proporção de resultados totalmente mal classificados (SHAN G, 2015; VILELA JUNIOR et al., 2022)

É calculado pela equação:

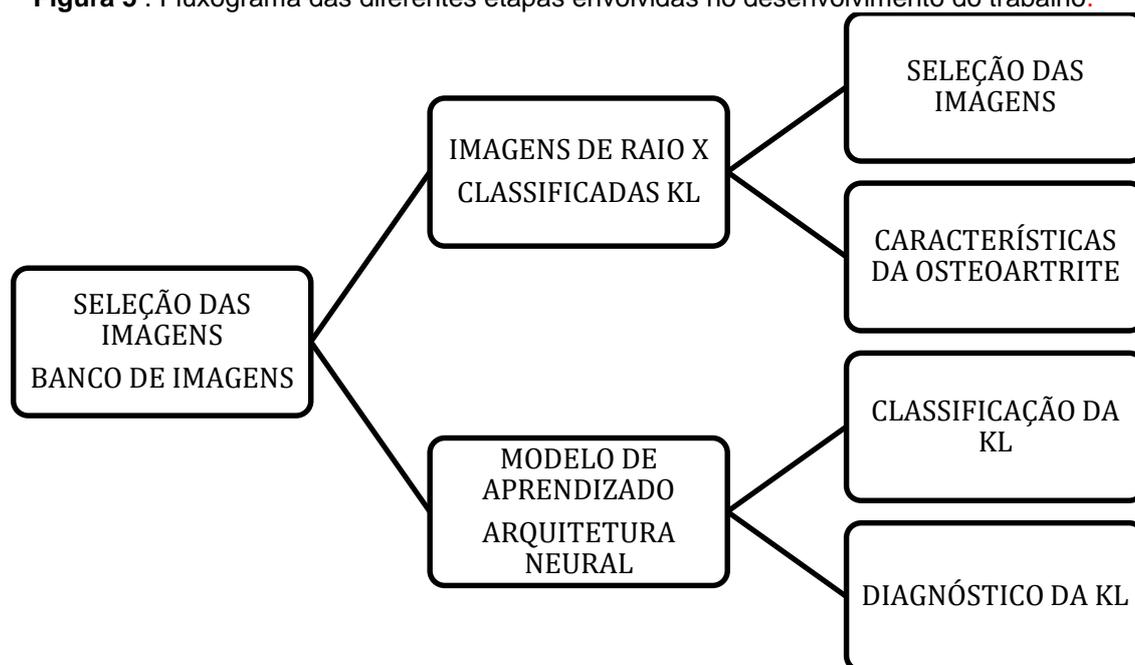
$$IY = [TP / (TP + FN)] + [TN / (FP + TN)] - 1$$

## **5 MATERIAIS E MÉTODOS**

Utilizou-se uma pesquisa descritiva de caráter quali quantitativo, e métodos da IA aplicados na análise do movimento humano a partir do projeto integrado sob o título: Métodos da inteligência artificial aplicados na análise do movimento humano, aprovado, CAAE: 33912120.9.0000.5507 com parecer do CEP: 4126546, fonte primária e norteador deste estudo (anexo 1).

Em sequência, apresentação do fluxograma da pesquisa, com todas as etapas dos tratamentos e análise dos resultados.

**Figura 5** . Fluxograma das diferentes etapas envolvidas no desenvolvimento do trabalho.

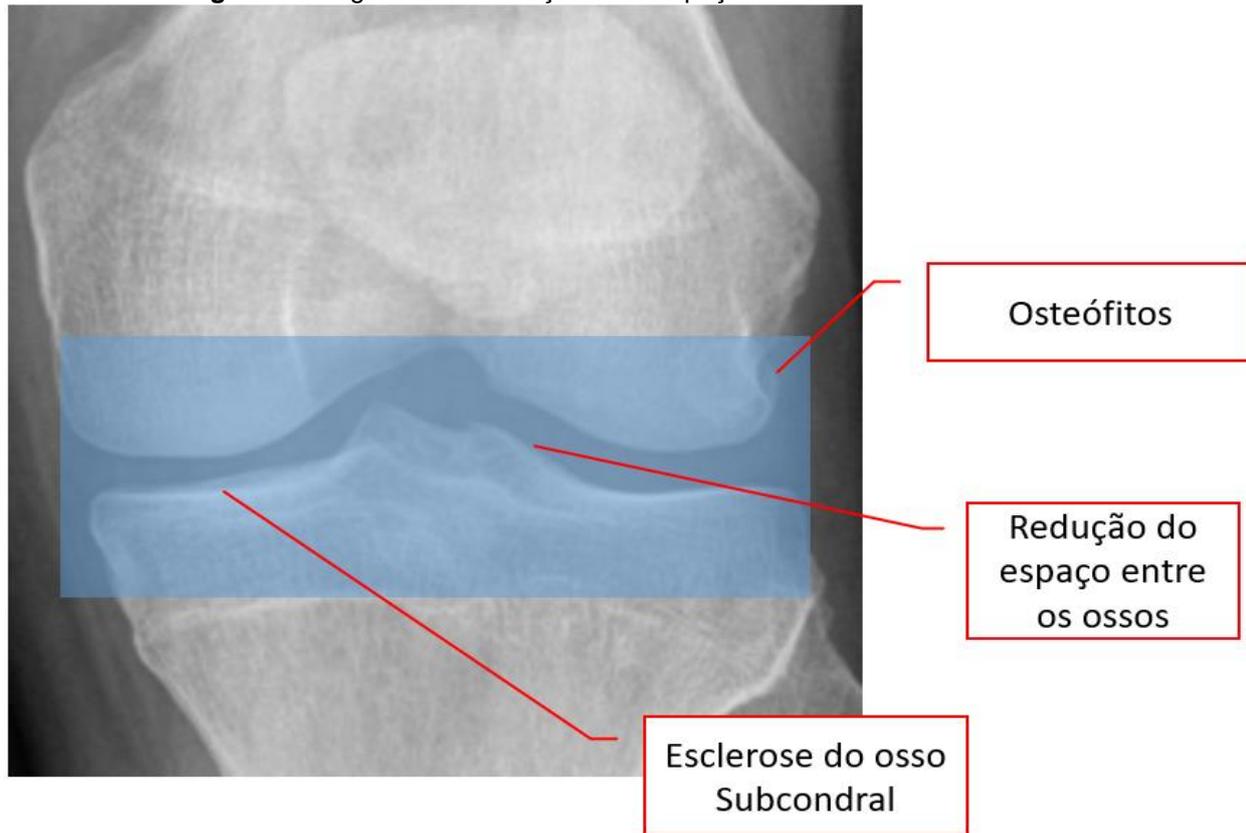


**Fonte:** Próprio autor.

### 5.1 Característica da amostra

Neste estudo, utilizou-se o conjunto de dados da Osteoartrite de Joelho disponível no portal kaggle (CHEN, 2018) Grau 0 - 3.085 imagens, Grau 1 - 1.416 imagens, Grau 2 - 2.062 imagens, Grau 3 - 1.029 imagens e Grau 4 - 236 imagens. Portanto, nesta pesquisa foram utilizadas 7.828 radiografias por conveniência. Um novo método baseado em aprendizado profundo foi utilizado para avaliação da OA de joelho em duas etapas: (1) localização das articulações do joelho nas imagens, (2) classificação de acordo com o sistema de classificação KL, conforme a Figura 6.

**Figura 6.** Imagem com marcações nos espaçamentos articulares



**Fonte:** Próprio autor

Foi utilizado a classificação internacional KL e em sequência foi atribuído o grau aos joelhos demonstrado na Figura 6 com os espaçamentos articulares.

- Grau 0: não há características radiográficas de OAJ;
- Grau 1: estreitamento do espaço articular duvidoso e possível protuberâncias nas extremidades articulares (osteófitos);
- Grau 2: osteófitos definidos;
- Grau 3: osteófitos múltiplos, deformidade óssea;
- Grau 4: osteófitos grandes, esclerose grave e deformidade óssea.

Os critérios de inclusão foram: homens e mulheres de 45 a 79 anos, com ou sem risco de OA de joelho femorotibial sintomática; de todas as minorias étnicas (foco em afro-americanos). Os critérios de exclusão foram sujeitos com artrite inflamatória (AR) e OA bilateral de joelho em estágio final.

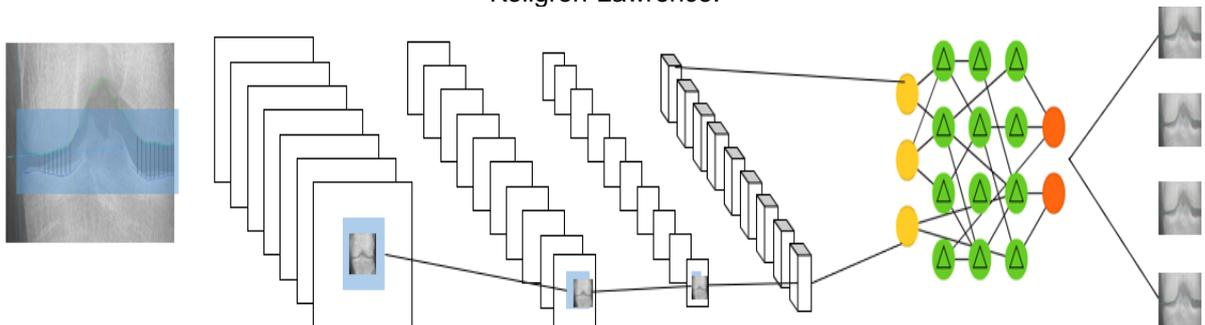
## 5.2 DATASET- Conjunto de dados com radiografias simples

O conjunto de dados kaggle (CHEN, 2018) apresenta escore de estreitamento de espaço entre as articulações e as avaliações de grau de osteófito. Dado este conjunto de dados original, realizamos algumas exclusões para chegar em um conjunto final usado para a análise. Após análise, as radiografias com baixa qualidade foram excluídas do conjunto de dados a serem trabalhados pela rede neural.

Inicialmente, para este tipo de classificação, foi necessária uma boa performance, geralmente alcançada através da utilização de Deep Learning, ou seja, uma rede neural de múltiplas camadas, mais especificamente uma rede neural convolucional. Foi utilizado camadas de convolução que, juntamente com outros tipos de camadas, determinam uma arquitetura específica para esta análise. Uma rede neural profunda possui camadas de neurônios: uma camada de entrada, algumas camadas intermediárias (ou ocultas), e uma camada de saída.

Por isso, a aplicação de camadas convolucionais sobre os pixels da imagem, reduz muito a quantidade de parâmetros e facilita a descoberta de padrões. Uma camada convolucional realiza o aprendizado de múltiplos filtros, onde cada filtro extrai uma informação da imagem. Posteriormente, foi utilizado a biblioteca Keras do Python® para desenvolvimento de uma CNN, sendo uma camada convolucional para imagens e também outras camadas (ou layers) para se utilizar em combinação sequencial nas convoluções conforme mostra a Figura 7.

**Figura 7.** Arquitetura DenseNet. As redes neurais convolucionais profundas são compostas por uma sequência de conjuntos de filtros convolucionais com parâmetros treinados a partir dos dados. KL = Kellgren-Lawrence.



Fonte: Próprio autor

No exemplo da arquitetura (figura 7), inicialmente foi adicionado uma imagem de radiografia de joelho do grau de osteoartrite 3, segundo a escala KL. Na etapa seguinte, aplicou-se as CNN que consiste em identificar e aprender sobre as características da imagem (camada layer). No processo de tratamento, foi duplicado e refinado a radiografia, com o objetivo de treinar o modelo com a maior quantidade de informações possíveis (camada *pooling*). E na última fase de agrupamento e geração de um conjunto de imagens, a partir do modelo de entrada (camada Flatten). Na etapa de classificação (camada dense), a rede neural é treinada a partir do conjunto de dados e gera os resultados de saída.

### 5.3 Importando bibliotecas

Fase composta pela importação das diferentes bibliotecas utilizadas nas camadas de construção do algoritmo, bem como nas camadas de filtros para identificação e aprendizagem das características da patologia osteoartrite.

Exemplo de código utilizado:

```
def show_image_samples(gen, class_names):
    class_dict=gen.class_indices
    new_dict={}
    # make a new dictionary with keys and values reversed
    for key, value in class_dict.items(): # dictionary is now {numeric class label:
string of class_name}
        new_dict[value]=key
```

## 5.4 Pré-processamento de imagens

As imagens importadas do banco de dados foram redimensionadas de acordo com o pixel (tons de cinza) usando algoritmos de interpolação.

Exemplo de programação, determinando as classes de imagem quanto suas características:

```
# determine the class weight dictionary
for i in range(len(class_totals)):
    print (' class: ', classes[i], ' totals_samples: ', class_totals[i])
max_samples=np.max(class_totals)
class_weight={}
for i in range (len(class_totals)):
    class_weight[i]=max_samples/class_totals[i]
print ('class weight: ',class_weight)
print(' total files: ',len(filepaths), ' total labels', len(labels))
```

## 5.5 O algoritmo para a estimativa de gravidade da osteoartrite do joelho

Os algoritmos são desenvolvidos para a análise de um extenso conjunto de dados e, ao longo do processo, são definidos e encontrados padrões e recursos através de uma aprendizagem da própria operação. Com isso, os algoritmos são capazes de tomar decisões e há um aumento gradativo nas previsões quando novos dados são analisados.

A abordagem consiste em dois passos: (1) detectar as articulações do joelho e (2) classificar as articulações do joelho em termos de OA. Juntas, essas duas etapas constituem um *baseline* totalmente automatizado, permitindo estimar o grau KL.

### 5.5.1 Passo 1: algoritmo de localização da articulação do joelho

Foram aplicadas camadas de treinamento e caixas de limitação de imagens previamente rotuladas ao redor do centro do joelho. Em seguida, foram aplicadas características adicionais ao algoritmo para identificar as estruturas a serem analisadas ao longo da estrutura articular.

Exemplo da camada de aprendizagem:

```
batch_size=32
image_shape=(224,224)
class_mode='categorical'
class_names=['minimal', 'healthy', 'moderate', 'severe']

length= len(test_df) # determine test batch size and test steps such that
test_batch_size X test_steps = number of test samples
test_batch_size=sorted([int(length/n) for n in range(1,length+1) if length % n
==0 and length/n<=batch_size],reverse=True)[0]
test_steps=int(length/test_batch_size)
print (' test batch size: ', test_batch_size, ' test steps: ', test_steps)
# create train, test, valid generators
def scaler(img): # normal preprocessing function used originally but poor
accuracy on test set
    return img/127.5 -1 # scale the pixels between -1 and + 1
def scalar(img):# try using adaptive thresholding on images to improve
training accuracy
    img=np.array(img, dtype='uint8')
    img=cv2.cvtColor(img, cv2.COLOR_RGB2GRAY)
    th2          =          cv2.adaptiveThreshold(img,          255,
cv2.ADAPTIVE_THRESH_MEAN_C, cv2.THRESH_BINARY, 21, 2);
    img=cv2.cvtColor(th2, cv2.COLOR_GRAY2RGB)
    img=np.array(img, dtype=('float32'))
    img=img/127.5-1
    return img
```

Após definir as funções e amostragem de imagens, a rede neural armazena as informações para começar o aprendizado e conseqüentemente pré-determinar e gerar novas imagens.

### 5.5.2 Passo 2: Classificação de gravidade da OA Joelho usando CNN multi-entrada

Foi aplicado uma abordagem baseada em uma arquitetura CNN multi-entrada, que treina e identifica diferentes tonalidades e características das imagens simultaneamente. Como mostrado na Fig.6, toda a rede consiste de dois ramos nas camadas iniciais, sendo que um corresponde a cada uma das radiografias de entrada. Cada fase consiste em camadas de convolução. Em cima das camadas convolucionais, adicionamos duas camadas totalmente conectadas para prever as pontuações de KL representando a gravidade da OA.

Após aplicação dos filtros e reconhecimento das características patológicas o algoritmo reconhece e classifica os graus da OAJ.

Exemplo de filtros e características das imagens após o algoritmo estabelecer os padrões da OA de joelho conforme a Figura 8.



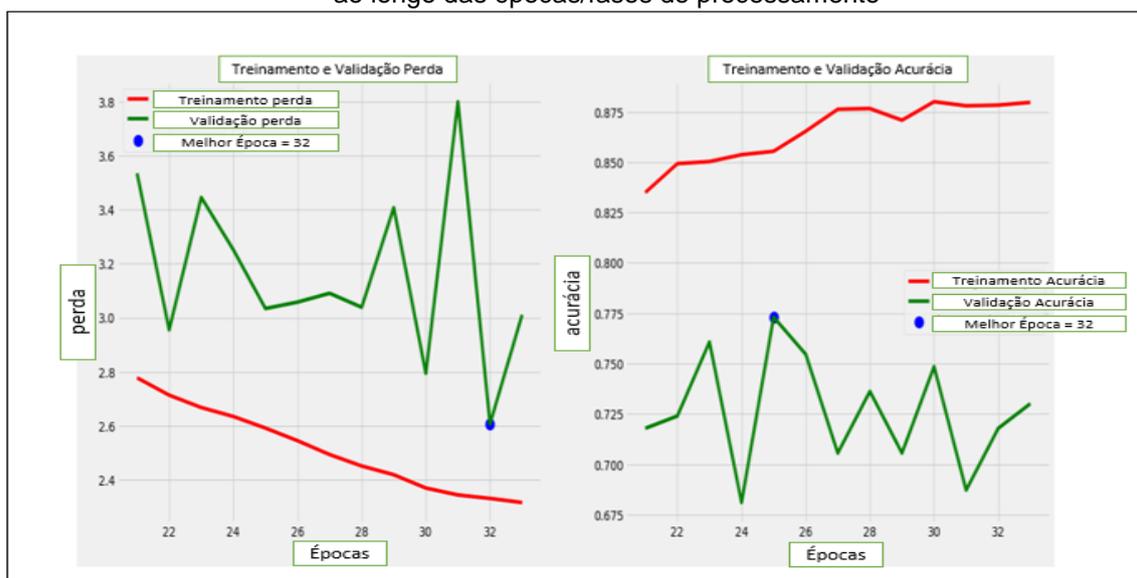
Fonte: Próprio autor

### 5.5.3 Passo 3: Fase de treinamento e validação do algoritmo

Foi utilizado a biblioteca Keras de aprendizado de máquina para desenvolver e construir modelos personalizados complexos para pesquisa e produção. A biblioteca Keras é considerado um nível de rede neural, escrito em Python®. Esta é uma rede neural de alto nível para construir e treinar modelos que incluem suporte de primeira classe para a funcionalidade específica do TensorFlow.

Em sequência, com o algoritmo estabelecido e preparado para treinar, foi treinado o modelo de Keras. Em seguida, foi aplicado os comandos e procedimentos: épocas e *validation\_data*, etapas para validação da literatura de aprendizado de máquina, medindo o desempenho do modelo após cada classe de treinamento conforme Figura 9.

**Figura 9.** Treinamento e validação das épocas. Gráfico reportando a fase de treinamento e validação ao longo das épocas/fases do processamento



Fonte: próprio autor.

## 6 RESULTADOS E DISCUSSÃO

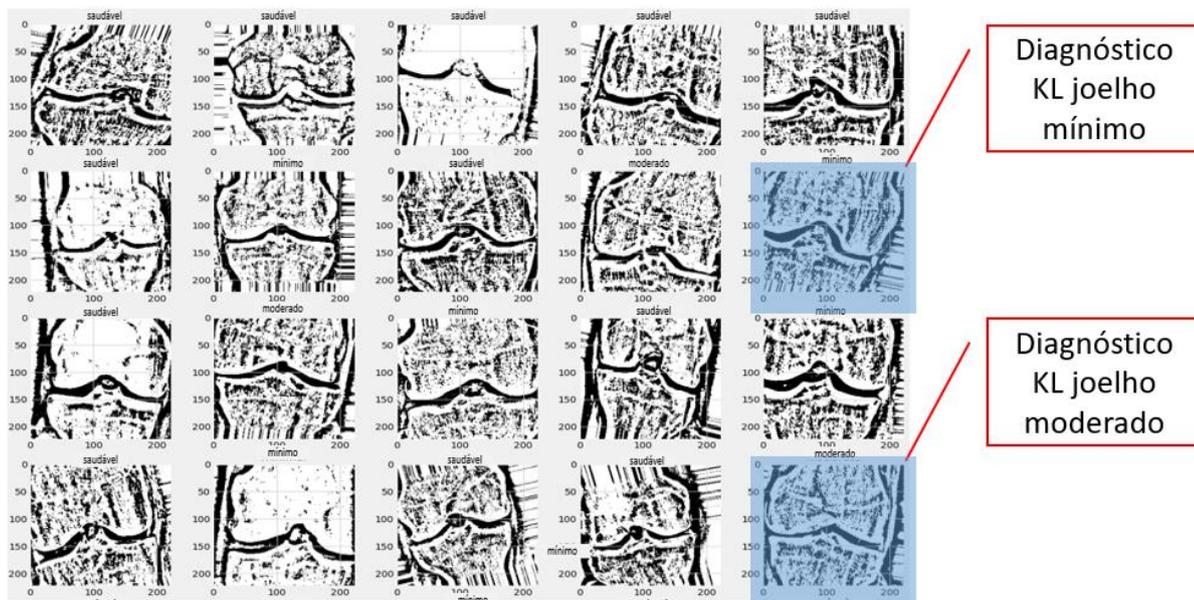
A OAJ sensibiliza mais de 250 milhões de pessoas em todo o mundo (aproximadamente de 4% da população mundial) (KOHN MD et al., 2016).

Atualmente, uma combinação de apresentação clínica e radiografia simples é considerada o principal diagnóstico de OAJ (PONGSAKONPRUTTIKUL et al., 2022).

Nos últimos anos, o aprendizado profundo surgiu como um campo popular de pesquisa no âmbito científico, especificamente no campo de radiografias/imagiologia em análises clínicas. Neste trabalho, apresentamos atualizações/aprimorações sobre a aplicação da rede CNN em modelos de segmentação e classificação. Diversas publicações sobre modelos CNN na pesquisa em OAJ têm sido aplicadas isoladamente ou combinadas com outras estratégias (YEOH et al., 2021). Ademais, foi desenvolvido um método baseado em Deep Learning para realizar uma graduação automática simultânea do diagnóstico KL, a partir de radiografias do joelho usando aprendizado de transferência.

Os filtros de tons de cinza foram então usados para examinar quais características da imagem de entrada o algoritmo estava identificando como importantes para a tomada de decisão conforme Figura 10.

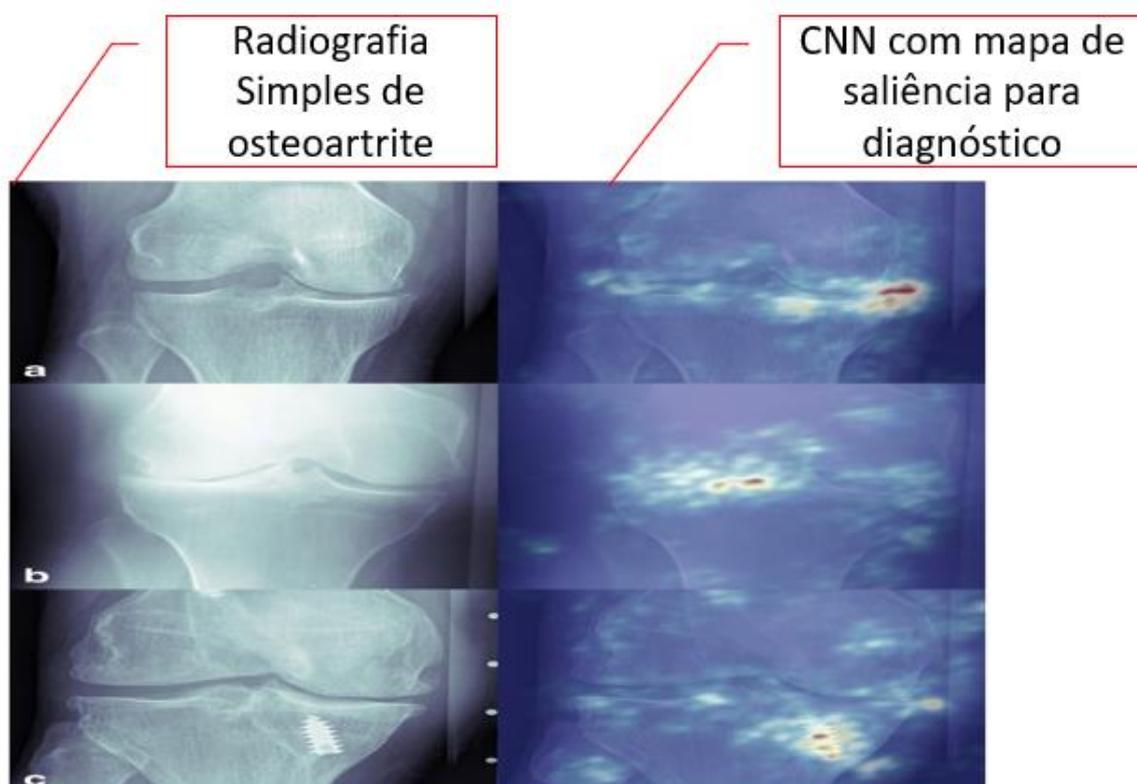
Figura 10. Exemplo de filtro para leitura das características da KL.



Fonte: Próprio autor

A CNN pode ser aplicada com diferentes filtros para análise, Norman e colaboradores utilizaram recentemente em sua pesquisa mapas de saliência (figura 10) para examinar quais características da imagem de entrada o algoritmo estava identificando como importantes para a tomada de decisão.

**Figura 11.** Mapas de saliência



**Fonte:** adaptado de (NORMAN et al., 2019)

Foram observadas na figura 11 as características relevantes: osteófitos e estreitamento do espaço articular. Para os casos em que o algoritmo classificou erroneamente a graduação do OAJ, muitas vezes foi devido à presença de prótese no joelho, apontando possíveis intervenções com essa técnica utilizada (NORMAN et al., 2019).

Após a construção do algoritmo e fases de treinamento e validação, foi gerado a matriz de confusão, utilizada especificamente para apresentar as principais métricas de efetividade numa CNN, através de sua performance.

**Figura 12.** Matriz de Confusão.

		Predição			
		saudável	mínimo	moderado	severo
Atual	Mínimo	34	8	2	0
	Saudável	14	33	4	0
	Moderado	0	8	42	3
	Severo	0	0	1	14

**Fonte:** Próprio autor

Em sequência, os resultados obtidos através da matriz de confusão, sendo calculado as métricas, acurácia, precisão, sensibilidade, especificidade, FMI, índice Youden e MCC (tabela 1).

**Tabela 1.** Resultado do diagnóstico: Acurácia, precisão, sensibilidade, especificidade, FMI, Índice Youden e MCC.

	SAUDÁVEL	MINIMO	MODERADO	SEVERO
<b>Acurácia</b>	0,79	0,85	0,89	0,98
<b>Precisão</b>	0,67	0,71	0,86	0,82
<b>Sensibilidade</b>	0,65	0,77	0,79	0,93
<b>Especificidade</b>	0,86	0,88	0,94	0,98
<b>FMI</b>	1,00	0,96	1,00	0,94
<b>Índice Youden</b>	0,65	0,51	0,73	0,91
<b>MCC</b>	0,64	0,51	0,73	0,86

**Fonte:** Próprio autor

No diagnóstico prescrito pelos especialistas na KL, foram relatados diferentes análises, como uma articulação saudável até mesmo em estado severo. Como observado na tabela 1, a acurácia apresentou 0,79 (joelho saudável), 0,85 (OAJ mínimo), 0,89 (OAJ moderado) e 0,98 (OAJ severo). Em comparação com o estudo de Thomas e colaboradores, o modelo teve uma pontuação média de 0,70 e uma acurácia de 0,71 para o conjunto de teste completo (THOMAS et al., 2020).

Ademais, na respectiva pesquisa, utilizou-se um subconjunto de 50 imagens com a análise de radiologistas experientes, onde, o melhor radiologista individual teve uma pontuação na variável acurácia de 0,60, em contrapartida, o modelo teve uma pontuação na acurácia de 0,66. Em consideração a comparação com uma análise humana, com especialistas (radiologistas), o algoritmo apresentou uma acurácia significativamente maior.

O presente estudo demonstrou uma precisão de 0,67 (joelho saudável), 0,71 (OAJ mínimo), 0,86 (OAJ moderado) e 0,82 (OAJ severo). As taxas de sensibilidade foram 0,65 (joelho saudável), 0,77 (OAJ mínimo), 0,79 (OAJ moderado) e 0,93 (severo), pesquisadores usando mapas de saliência produziram taxas de sensibilidade de teste da DenseNets de OAJ saudável, OAJ leve, moderado e grave foram 83,7, 70,2, 68,9 e 86,0%, respectivamente e as taxas de especificidade correspondentes foram 86,1, 83,8, 97,1 e 99,1% (NORMAN et al., 2019).

O estudo de Tiulpin e colaboradores produziram os novos resultados de última geração na classificação KL, apresentando uma acurácia equilibrada de 66,71% (TIULPIN et al., 2018b). Em contrapartida, o algoritmo desenvolvido obteve uma acurácia equilibrada em média de 0,85, mostrando uma melhora na performance comparado com as últimas pesquisas desenvolvidas na mesma temática. Quando

comparado com a performance e análise clínica de cirurgião ortopédico, a CNN demonstrou sua eficácia. A pesquisa de Schwartz e colaboradores 2020, utilizaram quatro cirurgiões especialistas em artroplastia de joelho usando o sistema de pontuação do International Knee Documentation Committee (IKDC).

Foram analisadas 4755 imagens, com a acurácia dos cirurgiões e a aplicação da CNN no diagnóstico. O intervalo de confiança (ICC) entre os 4 cirurgiões para todos os graus possíveis do IKDC foi de 0,703. O ICC para os 4 cirurgiões e a CNN treinada foi de 0,685 (IC 95% 0,65-0,719), indicando que a CNN pode identificar e classificar a OA de joelho com a mesma acurácia de um cirurgião treinado (SCHWARTZ AJ et al., 2020).

Em vista que, a OAJ afeta diferentes populações, e também diferentes faixas etárias, Leung e colaboradores, utilizaram radiografias simples de indivíduos com média de idade entre 45 e 79 anos. Os voluntários foram pareados aos pacientes controle de acordo com idade, sexo, etnia e índice de massa corporal. O modelo proposto utilizou uma abordagem de aprendizagem por transferência baseada na arquitetura ResNet. Em sequência, foram avaliados 728 participantes, incluindo 324 pacientes (idade média, 64 anos  $\pm$  8, 222 mulheres). O modelo de previsão baseado em DL alcançou uma acurácia de 0,87 (LEUNG et al., 2020).

Foi calculado o índice Fowlkes– Mallows (FMI) obtendo valores de (1,00) joelho saudável, (0,96) joelho mínimo, (1,00) joelho moderado e (0,94) para joelho severo, sendo valores ótimos quando comparado as principais referências atuais, utilizando os métodos e filtros semelhantes. Em referência, os valores mínimos possíveis do índice Fowlkes– Mallows é 0, que representa uma classificação binária de baixa qualidade, cujas variáveis apresentam erros. Ademais, o valor máximo possível do

índice de Fowlkes– Mallows é 1, que corresponde à melhor classificação binária possível, cujos elementos foram perfeitamente classificados; sendo bastante eficiente para clusters de dados independentes, evidenciando a eficiência da CNN desenvolvida (VILELA JUNIOR et al., 2022). Estudo recente desenvolveu uma Rede de reconhecimento de padrões com objetivo de distinguir pacientes com câncer de mama de pessoas saudáveis. O melhor desempenho de classificação foi obtido usando um modelo com duas camadas ocultas com 11 e 100 neurônios na rede apresentando valores de FMI (0,94) (GÜNDOĞDU, 2021).

Na tabela 1 é apresentado os valores do índice Youden, utilizado na classificação da rede neural, foram observados valores de 0,65 (joelho OA saudável), 0,51 (joelho OA mínimo), 0,73 (joelho OA moderado) e 0,91 (joelho OA severo). Este índice é utilizado como parâmetro em análise, visando as variáveis sensibilidade e especificidade, o estudo de Liu e colaboradores 2018, desenvolveram uma CNN para detectar lesões de cartilagem na articulação do joelho em imagens de ressonância magnética, tendo como resultados um índice de 0,84, sendo considerado valor ótimo. Colaborando para os achados da pesquisa, a CNN obteve índice de 0,91 na classificação de OAJ severo.

A utilização de uma rede neural, pode assumir diversas aplicabilidades no ambiente clínico, principalmente no diagnóstico e direcionamento em tratamentos não cirúrgicos e invasivos, nesse sentido, Boswell e colaboradores, avaliaram o momento de adução de joelho em sujeitos com OAJ. Foram utilizados análise de vídeo para verificar a viabilidade de prever o pico de adução durante os padrões naturais e modificados de caminhada usando as posições dos pontos de referência anatômicos.

Foram utilizados 86 indivíduos (64 com osteoartrite de joelho, 22 sem OA) andando naturalmente e com modificações no ângulo de progressão do pé. Foi treinado uma rede neural para prever o pico adução usando as posições tridimensionais de 13 pontos de referência anatômicos medidos com captura de movimento (rede neural 3D). Ao final do estudo, a rede neural foi capaz de prever os movimentos e análises com acurácia de 85%, colaborando para outras pesquisas, que utilizam de movimentos em 3D para análise do movimento (BOSWELL et al., 2021).

A ultrassonografia é uma modalidade de imagem que utiliza pulsos refletidos de ondas sonoras de alta frequência (ultrassônicas) para avaliar tecidos moles, cartilagem, superfícies ósseas e estruturas contendo fluido. A utilização de imagem, específica dos radiologistas, tornou-se amplamente disponível em clínicas de reumatologia e outros ambientes ambulatoriais e de emergência (YEAP et al., 2017).

Utilizando desta técnica, Zhao e colaboradores (2021), exploraram a aplicação da imagem de ultrassom com base no algoritmo de rede neural de retropropagação na OAJ e avaliar o efeito da aplicação e o valor da tecnologia de imagem de ultrassom com base na rede neural no diagnóstico de lesões da cartilagem da OAJ, 98 pacientes com diagnóstico de OAJ foram submetidos a exames artroscópicos de tecidos moles e selecionados aleatoriamente. Os resultados mostraram que a acurácia de estadiamento do grupo controle foi de 68,3% e a do grupo experimental foi de 76,9%. A acurácia do estadiamento da degeneração da cartilagem do grupo experimental foi maior do que a do grupo controle.

A CNN desenvolvida em nosso estudo obteve resultados relevantes em comparação as pesquisas mais recentes com imagens, o estudo de Bany Muhammad e colaboradores trabalhou com um conjunto de 22.796 radiografias na sua base de

dados. A respectiva pesquisa, demonstrou um desempenho dos modelos básicos da CNN variando de 0,69 a 0,71% de acurácia em média, em contrapartida, foi apresentado uma acurácia em nosso modelo de CNN em média 0,67 à 0,86 (BANY MUHAMMAD et al., 2021).

Em suma, diversos trabalhos foram desenvolvidos e publicados utilizando como abordagem do aprendizado profundo com ênfase na performance da geração de classificação da OAJ, um resumo dos principais achados no direcionamento da rede CNN na classificação e diagnóstico da OAJ é apresentado no Quadro 1.

**QUADRO 1.** Classificação CNN na gravidade da OAJ

<b>Autores</b>	<b>Objetivo do estudo</b>	<b>Tipo de Imagem</b>	<b>Conjunto de dados</b>	<b>Arquitetura de rede</b>	<b>Resultados</b>
<b>Tiulpin et al., 2018</b>	OA do joelho com base no grau KL	Raio X (radiografia simples)	18376 imagens	Rede neural convolucional	AUC: 0,93
<b>Nguyen et al., 2020</b>	OA do joelho com base no grau KL	Raio X (radiografia simples)	OAI: 39.902 imagens	Rede neural convolucional	Cohen's Kappa coeficiente (KC): 0,790
<b>Nguyen et al., 2020</b>	OA do joelho com base no grau KL	Raio X (radiografia simples)	39.902 imagens	aprendizagem semisupervisionada profunda	Acurácia: 71 ± 0,8%
<b>Liu et al., 2020</b>	OA do joelho com base no grau KL	Raio X (radiografia simples)	2770 imagens	CNN	Acurácia: 82,5%; SN: 78,2%; SP: 94,8%
<b>Norman et al., 2019</b>	OA do joelho com base no grau KL	Raio X (radiografia simples)	39.593 imagens	DenseNet	SN: 83,7 (sem OA), 70,2 (OA leve), 68,9 (OA moderado), 86,0 (OA grave) %
<b>Zhang et al., 2020</b>	OA do joelho com base no grau KL	Raio X (radiografia simples)	OAI: 38.232 imagens	ResNet	Acurácia: 74,81%
<b>Leung et al., 2020</b>	OA do joelho com base no grau KL	Raio X (radiografia simples)	OAI: 728 sujeitos	ResNet	AUC: 0,87
<b>Tiulpin e Saarakkala</b>	OA do joelho com base no grau KL	Raio X (radiografia simples)	OAI: 19704 imagens	ResNet	AUC: 0,98

**Fonte:** adaptado de YEOH et al., 2021

Osteoarthritis Initiative (OAI); arquitetura de rede: rede neural convolucional (CNN) especificidade (SP), sensibilidade (SN), acurácia (AUC)

Pesquisas atuais utilizam a radiografia simples do joelho em seu modelo de classificação, não apenas porque é comumente disponível e econômica, mas também porque as características mais significativas da OAJ são estreitamento do espaço articular (EA) e formação de osteófitos que podem ser facilmente visualizados por radiografias do joelho. Além disso, o EA desempenha um papel importante na determinação da gravidade da OAJ de acordo com o grau KL, que é uma classificação comumente usada por profissionais em todo o mundo (TIULPIN et al., 2019; WAHYUNINGRUM et al., 2019; YEOH et al., 2021)

O sistema de classificação KL (como mostrado na Figura 1, pág. 19) é caracterizado em cinco graus com base na verdade em que o Grau 0 indica ausência de OAJ, Grau 1 indica OAJ duvidosa com osteófitos diminutos, Grau 2 indica OAJ leve com osteófitos definidos, Grau 3 indica OAJ moderado com EA definido e múltiplos osteófitos com possível osso deformação, e o Grau 4 indica OAJ grave, onde grandes osteófitos, EA, esclerose grave e deformidade óssea definida estão presentes (WAHYUNINGRUM, et al., 2019).

O grau KL define a gravidade da OAJ como uma pontuação composta e é subjetiva com base na interpretação do profissional, causando um certo nível de incerteza no diagnóstico da OAJ (CHAUDHARI, et al., 2020). Clinicamente, médicos e especialistas em imagiologia fazem uso de técnicas diferentes, como ressonância magnética (RM), tomografias, ultrassonografias e radiografia simples, porém, todos os métodos acarretam diferentes custos operacionais.

A análise da articulação do joelho em uma perspectiva 3D identifica uma visão precisa da articulação, em especialmente da cartilagem articular, para uma melhor varredura das doenças da OAJ. Pesquisas evidenciam que as imagens de RM 3D

resultam em um favorável desempenho que as radiografias 2D (raio x), com maior sensibilidade e especificidade, principalmente na detecção precoce de OAJ (TOLPADI et al., 2020)

No entanto, atualmente os pesquisadores estão concentrados em arquiteturas CNN 2D ou na adoção apenas de menores volumes de imagens 3D em CNN 3D em função da baixa capacidade de memória nas máquinas/computadores (EBRAHIMKHANI et al., 2020).

## 7 CONSIDERAÇÕES FINAIS

Este estudo apresenta a utilização e aplicação do aprendizado profundo como uma ferramenta promissora para o diagnóstico auxiliado por algoritmos inteligentes para a doença da osteoartrite do joelho. A técnica e análise clínica convencional para diagnosticar a osteoartrite é interpretar/identificar imagens de radiografia simples visualmente, onde a avaliação manual apresenta um grau mais elevado no diagnóstico da progressão da osteoartrite de início precoce. Os profissionais médicos ortopedistas optam pela radiografia simples ao invés da tomografia computadorizada, por alguns motivos, custo elevados dos exames e por característica visíveis nas imagens radiográficas, sendo assim, de uso comum em hospitais, clínicas de reabilitação, entre outros espaços destinados nas análises clínicas em imagem.

Nesse sentido, o papel da inteligência artificial, em específico, o aprendizado profundo é uma tecnologia importante no desenvolvimento de auxílio à decisão clínica e precisa da osteoartrite de joelho.

Ademais, como evidenciado na pesquisa desenvolvida, a CNN no universo de imagens médicas avançou significativamente nos últimos anos e tem demonstrado grande potencial no diagnóstico da OAJ. Em virtude do exponencial evolução tecnológica e avanços nas áreas da inteligência artificial e disponibilidade de dados, o aprendizado profundo, rede neural convolucional poderá potencializar o diagnóstico precoce da osteoartrite do joelho.

O diagnóstico da osteoartrite, através de imagem simples permite a avaliação da articulação do joelho e oferece informações precisas da sensível progressão da doença.

Entretanto, desenvolver uma rede neural sólida e generalizada em aplicações diagnósticas ainda apresenta ser uma tarefa desafiadora e continua sendo uma área de pesquisa em aberto, com objetivo a precisão do modelo e eficácia computacional. Embora a aplicação da CNN ainda se encontra em fase prévio, evidenciamos o desenvolvimento e aplicabilidade do método de CNN baseados em imagens de radiografia simples oferecerá melhor compreensão sobre a progressão da doença OA, em especial na detecção precoce de OA na articulação do joelho. A CNN desenvolvida, com um conjunto de dados reduzido mostrou acurácia e precisão na média e superior da maioria dos estudos desenvolvido na mesma linha de pesquisa.

O futuro da prática clínica poderá utilizar de ferramentas e aplicativos clínicos automatizados para desfrutar de novas possibilidades, não somente na identificação de biomarcadores, mas na evolução em excelente desempenho superando a precisão e fidedignidade de profissionais clínicos no diagnóstico precoce de OAJ.

O desenvolvimento e aplicabilidade da CNN no âmbito clínico, em análises e interpretações de imagens radiológicas traz diversos benefícios, desde orientações, diagnósticos, prevenções e evoluções na triagem de pacientes com complicações oriundas da patologia.

Em suma, a aplicabilidade nas ciências do movimento humano, abre caminhos e possibilidades para os diversos profissionais, médicos, fisioterapeutas, profissionais de educação física, fisiologistas, tanto no cenário clínico/hospitalar como nos diversos campos de atuação esportivo.

Por outro lado, pensando no paciente em quadro de OAJ, o impacto no movimento humano torna-se sem igual, podendo reduzir os danos, melhores

orientações, diagnósticos precisos, diminuindo os processos de reabilitação, sendo potencialmente aplicável em todas as esferas circunscritas à patologia, colaborando diretamente na qualidade de vida e capacidade funcional dos mesmos.

## 7 REFERÊNCIAS

BANY MUHAMMAD M, YEASIN M. Interpretable and parameter optimized ensemble model for knee osteoarthritis assessment using radiographs. **Sci Rep.** 2021 Jul 12;11(1):14348. doi: 10.1038/s41598-021-93851-z. PMID: 34253839; PMCID: PMC8275586.

BELLUZZI, E. et al. Infrapatellar Fat Pad Gene Expression and Protein Production in Patients with and without Osteoarthritis. **International Journal of Molecular Sciences**, v. 21, n. 17, p. 1–15, 1 set. 2020.

BOSWELL MA, UHLRICH SD, KIDZIŃSKI Ł, THOMAS K, KOLESAR JA, GOLD GE, BEAUPRE GS, DELP SL. A neural network to predict the knee adduction moment in patients with osteoarthritis using anatomical landmarks obtainable from 2D video analysis. **Osteoarthritis Cartilage.** 2021 Mar;29(3):346-356. doi: 10.1016/j.joca.2020.12.017. Epub 2021 Jan 7. PMID: 33422707; PMCID: PMC7925428.

BRAHIM A, Jennane R, Riad R, Janvier T, Khedher L, Toumi H, Lespessailles E. A decision support tool for early detection of knee osteoarthritis using X-ray imaging and machine learning: Data from the OsteoArthritis Initiative. **Comput Med Imaging Graph** 2019; 73: 11-18.

CALLAHAN LF, CLEVELAND RJ, ALLEN KD, GOLIGHTLY Y. Racial/Ethnic, Socioeconomic, and Geographic Disparities in the Epidemiology of Knee and Hip

Osteoarthritis. **Rheum Dis Clin North Am.** 2021 Feb;47(1):1-20. doi: 10.1016/j.rdc.2020.09.001. Epub 2020 Oct 29. PMID: 34042049; PMCID: PMC8248516.

CHEN, P. Knee Osteoarthritis Severity Grading Dataset. v. 1, 2018.

CHEN, P. et al. Fully automatic knee osteoarthritis severity grading using deep neural networks with a novel ordinal loss. **Computerized Medical Imaging and Graphics**, v. 75, p. 84–92, 1 jul. 2019.

CHU, C. R.; MILLIS, M. B.; OLSON, S. A. Osteoarthritis: From Palliation to Prevention: AOA Critical Issues. **The Journal of Bone and Joint Surgery. American volume**, v. 96, n. 15, p. e130(1), 8 ago. 2014.

CROSS M, SMITH E, HOY D, NOLTE S, ACKERMAN I, FRANSEN M, BRIDGETT L, WILLIAMS S, GUILLEMIN F, HILL CL, LASLETT LL, JONES G, CICUTTINI F, OSBORNE R, VOS T, BUCHBINDER R, WOOLF A, MARCH L. The global burden of hip and knee osteoarthritis: estimates from the global burden of disease 2010 study. **Ann Rheum Dis.** 2014 Jul;73(7):1323-30. doi: 10.1136/annrheumdis-2013-204763. Epub 2014 Feb 19. PMID: 24553908

CULVENOR, A. G. et al. Defining the presence of radiographic knee osteoarthritis: a comparison between the Kellgren and Lawrence system and OARSI atlas criteria.

**Knee surgery, sports traumatology, arthroscopy : official journal of the ESSKA,**

v. 23, n. 12, p. 3532–3539, 1 dez. 2015.

ERICKSON, B. J. et al. Machine Learning for Medical Imaging.

<https://doi.org/10.1148/rg.2017160130>, v. 37, n. 2, p. 505–515, 17 fev. 2017.

ESTEVA, A. et al. Dermatologist-level classification of skin cancer with deep neural networks. **Nature** 2017 **542:7639**, v. 542, n. 7639, p. 115–118, 25 jan. 2017.

FARAH, H. et al. Differential Metabotypes in Synovial Fibroblasts and Synovial Fluid in Hip Osteoarthritis Patients Support Inflammatory Responses. **International journal of molecular sciences**, v. 23, n. 6, 1 mar. 2022.

GOSSEC, L. et al. Comparative evaluation of three semi-quantitative radiographic grading techniques for knee osteoarthritis in terms of validity and reproducibility in 1759 X-rays: report of the OARSI-OMERACT task force. **Osteoarthritis and cartilage**, v. 16, n. 7, p. 742–748, jul. 2008.

GÜNDOĞDU S. Improving breast cancer prediction using a pattern recognition network with optimal feature subsets. **Croat Med J.** 2021 Oct 31;62(5):480-487. doi: 10.3325/cmj.2021.62.480. PMID: 34730888; PMCID: PMC8596469.

HERNÁNDEZ-VAQUERO, D.; FERNÁNDEZ-CARREIRA, J. M. Relationship between radiological grading and clinical status in knee osteoarthritis. a multicentric study. **BMC Musculoskeletal Disorders**, v. 13, n. 1, p. 1–8, 9 out. 2012.

HOUARD, X.; GOLDRING, M. B.; BERENBAUM, F. Homeostatic Mechanisms in Articular Cartilage and Role of Inflammation in Osteoarthritis. **Current rheumatology reports**, v. 15, n. 11, p. 375, nov. 2013.

HUA, K. L. et al. Computer-aided classification of lung nodules on computed tomography images via deep learning technique. **OncoTargets and therapy**, v. 8, p. 2015, 4 ago. 2015.

HUANG Z, DING C, LI T, YU SP. Current status and future prospects for disease modification in osteoarthritis. **Rheumatology (Oxford)**. 2018 May 1;57(suppl\_4):iv108-iv123. doi: 10.1093/rheumatology/kex496. PMID: 29272498.

JANG, S.; LEE, K.; JU, J. H. Recent Updates of Diagnosis, Pathophysiology, and Treatment on Osteoarthritis of the Knee. **International journal of molecular sciences**, v. 22, n. 5, p. 1–15, 1 mar. 2021.

KATZ, J. N.; ARANT, K. R.; LOESER, R. F. Diagnosis and treatment of hip and knee osteoarthritis: A review. **JAMA**, v. 325, n. 6, p. 568, 2 fev. 2021.

KELLGREN, J. H.; LAWRENCE, J. S. Radiological Assessment of Osteo-Arthrosis. **Annals of the Rheumatic Diseases**, v. 16, n. 4, p. 494, 1957a.

KELLGREN, J. H.; LAWRENCE, J. S. Radiological assessment of osteo-arthrosis. **Annals of the rheumatic diseases**, v. 16, n. 4, p. 494–502, 1957b.

KNIPE, H.; PAI, V. Kellgren and Lawrence system for classification of osteoarthritis. **Radiopaedia.org**, 21 jan. 2014.

KOHN, M. D.; SASSOON, A. A.; FERNANDO, N. D. Classifications in Brief: Kellgren-Lawrence Classification of Osteoarthritis. **Clinical Orthopaedics and Related Research**, v. 474, n. 8, p. 1886, 1 ago. 2016.

KOOI, T. et al. Large scale deep learning for computer aided detection of mammographic lesions. **Medical Image Analysis**, v. 35, p. 303–312, 1 jan. 2017.

KOHN MD, SASSOON AA, FERNANDO ND. Classifications in Brief: Kellgren-Lawrence Classification of Osteoarthritis. **Clin Orthop Relat Res** 2016; 474: 1886-1893.

KRIZHEVSKY, I. SUTSKEVER E GE HINTON, "Classificação de imagem com redes neurais convolucionais profundas", **Advances in Neural Information Processing Systems** , vol. 25, pp. 1097-1105, 2012.

LANE NE, BRANDT K, HAWKER G, PEEVA E, SCHREYER E, TSUJI W, HOCHBERG MC. OARSI-FDA initiative: defining the disease state of osteoarthritis. *Osteoarthritis Cartilage*. 2011 May;19(5):478-82. doi: 10.1016/j.joca.2010.09.013.

LEUNG K, ZHANG B, TAN J, SHEN Y, GERAS KJ, BABB JS, CHO K, CHANG G, DENIZ CM. Prediction of Total Knee Replacement and Diagnosis of Osteoarthritis by Using Deep Learning on Knee Radiographs: Data from the Osteoarthritis Initiative. *Radiology*. 2020 Sep;296(3):584-593. doi: 10.1148/radiol.2020192091. Epub 2020 Jun 23.

LI D, LI S, CHEN Q, XIE X. The Prevalence of Symptomatic Knee Osteoarthritis in Relation to Age, Sex, Area, Region, and Body Mass Index in China: A Systematic Review and Meta-Analysis. *Front Med (Lausanne)*. 2020 Jul 16;7:304. doi: 10.3389/fmed.2020.00304. PMID: 32766258; PMCID: PMC7378378.

LIND, A. et al. Artificial intelligence for the classification of fractures around the knee in adults according to the 2018 AO/OTA classification system. *PloS one*, v. 16, n. 4, 1 abr. 2021.

LINDSEY, R. et al. Deep neural network improves fracture detection by clinicians. *Proceedings of the National Academy of Sciences of the United States of America*, v. 115, n. 45, p. 11591–11596, 6 nov. 2018.

LIU, B.; LUO, J.; HUANG, H. Toward automatic quantification of knee osteoarthritis severity using improved Faster R-CNN. **International Journal of Computer Assisted Radiology and Surgery** 2020 15:3, v. 15, n. 3, p. 457–466, 14 jan. 2020.

LIU F, ZHOU Z, SAMSONOV A, BLANKENBAKER D, LARISON W, KANAREK A, LIAN K, KAMBHAMPATI S, KIJOWSKI R. Deep Learning Approach for Evaluating Knee MR Images: Achieving High Diagnostic Performance for Cartilage Lesion Detection. **Radiology**. 2018 Oct;289(1):160-169. doi: 10.1148/radiol.2018172986. Epub 2018 Jul 31. PMID: 30063195; PMCID: PMC6166867.

LONG, E. SHELHAMER E T. DARRELL, “Redes totalmente convolucionais para segmentação semântica”, em 2015 IEEE **Conference on Computer Vision and Pattern Recognition (CVPR)** , pp. 3431–3440, Boston, MA, EUA, 2015.

MACCHI, V. et al. The infrapatellar fat pad and the synovial membrane: an anatomofunctional unit. **Journal of anatomy**, v. 233, n. 2, p. 146–154, 1 ago. 2018.

MAIESE, K. Picking a bone with WISP1 (CCN4): new strategies against degenerative joint disease. **Journal of translational science**, v. 1, n. 3, p. 83, 2016.

MORA, J. C.; PRZKORA, R.; CRUZ-ALMEIDA, Y. Knee osteoarthritis: pathophysiology and current treatment modalities. **Journal of Pain Research**, v. 11, p. 2189, 2018.

NORMAN, B. et al. Applying Densely Connected Convolutional Neural Networks for Staging Osteoarthritis Severity from Plain Radiographs. **Journal of digital imaging**, v. 32, n. 3, p. 471–477, 15 jun. 2019.

OLSSON, S. et al. Automating classification of osteoarthritis according to Kellgren-Lawrence in the knee using deep learning in an unfiltered adult population. **BMC musculoskeletal disorders**, v. 22, n. 1, 1 dez. 2021.

O'NEILL, T. W.; FELSON, D. T. Mechanisms of Osteoarthritis (OA) Pain. **Current Osteoporosis Reports**, v. 16, n. 5, p. 611, 1 out. 2018.

PARK JH, HONG JY, HAN K, SUH SW, PARK SY, YANG JH, HAN SW. Prevalence of symptomatic hip, knee, and spine osteoarthritis nationwide health survey analysis of an elderly Korean population. **Medicine (Baltimore)**. 2017 Mar;96(12):e6372. doi: 10.1097/MD.00000000000006372. PMID: 28328825; PMCID: PMC5371462.

PONGSAKONPRUTTIKUL N, ANGTHONG C, KITTICHA V, CHUWONGIN S, PUENGPATTRAKUL P, THONGPAT P, BOONSANG S, TONGLOY T. Artificial intelligence assistance in radiographic detection and classification of knee osteoarthritis and its severity: a cross-sectional diagnostic study. **Eur Rev Med Pharmacol Sci**. 2022 Mar;26(5):1549-1558. doi: 10.26355/eurrev\_202203\_28220. PMID: 35302199.

SASEK, C. An update on primary care management of knee osteoarthritis. **Journal of the American Academy of Physician Assistants**, v. 28, n. 1, p. 37–43, 3 jan. 2015.

SCHWARTZ AJ, CLARKE HD, SPANGEHL MJ, BINGHAM JS, ETZIONI DA, NEVILLE MR. Can a Convolutional Neural Network Classify Knee Osteoarthritis on Plain Radiographs as Accurately as Fellowship-Trained Knee Arthroplasty Surgeons? **J Arthroplasty**. 2020 Sep;35(9):2423-2428. doi: 10.1016/j.arth.2020.04.059. Epub 2020 Apr 25. PMID: 32418746.

SHEEHY, L. et al. Validity and sensitivity to change of three scales for the radiographic assessment of knee osteoarthritis using images from the Multicenter Osteoarthritis Study (MOST). **Osteoarthritis and cartilage / OARS, Osteoarthritis Research Society**, v. 23, n. 9, p. 1491, 1 set. 2015.

SHEN, D.; WU, G.; SUK, H. IL. Deep Learning in Medical Image Analysis. <https://doi.org/10.1146/annurev-bioeng-071516-044442>, v. 19, p. 221–248, 20 jun. 2017.

SWIECICKI, A. et al. Deep learning-based algorithm for assessment of knee osteoarthritis severity in radiographs matches performance of radiologists. **Computers in biology and medicine**, v. 133, 1 jun. 2021.

THOMAS, K. A. et al. Automated Classification of Radiographic Knee Osteoarthritis Severity Using Deep Neural Networks. **Radiology. Artificial intelligence**, v. 2, n. 2, p. e190065, 1 mar. 2020.

TING, D. S. W. et al. Development and Validation of a Deep Learning System for Diabetic Retinopathy and Related Eye Diseases Using Retinal Images From Multiethnic Populations With Diabetes. **JAMA**, v. 318, n. 22, p. 2211–2223, 12 dez. 2017.

TIULPIN, A. et al. Automatic Knee Osteoarthritis Diagnosis from Plain Radiographs: A Deep Learning-Based Approach. **Scientific Reports 2018 8:1**, v. 8, n. 1, p. 1–10, 29 jan. 2018a.

TIULPIN, A. et al. Automatic Knee Osteoarthritis Diagnosis from Plain Radiographs: A Deep Learning-Based Approach. **Scientific Reports**, v. 8, n. 1, 1 dez. 2018b.

VILELA JUNIOR, G. B. et al. Determinação Das Métricas Usuais A Partir Da Matriz De Confusão De Classificadores Multiclasses Em Algoritmos Inteligentes Nas Ciências Do Movimento HUMANO. **Revista CPAQV - Centro de Pesquisas Avançadas em Qualidade de Vida - CPAQV Journal**, v. 14, n. 2, 29 mar. 2022.

VILELA JUNIOR, G. B., LIMA, B. N., RIBEIRO, H. F., RODRIGUES, M. F., DE ALMEIDA PEREIRA, A., DE OLIVEIRA, J. R. L., ... & PASSOS, R. P. (2022). Importância Do Índice Fowlkes-Mallows (FMI), Do Coeficiente De Correlação De Matthews (MCC) E Do Índice Youden (IY) Nos Classificadores De Inteligência Artificial Na Área Da Saúde. **Revista CPAQV–Centro de Pesquisas Avançadas em Qualidade de Vida** | Vol, 14(3), 2.

VINA ER, KWONG CK. Epidemiology of osteoarthritis: literature update. **Curr Opin Rheumatol**. 2018 Mar;30(2):160-167. doi: 10.1097/BOR.0000000000000479. PMID: 29227353; PMCID: PMC5832048.

WAITE, S. et al. Interpretive Error in Radiology. <https://doi.org/10.2214/AJR.16.16963>, v. 208, n. 4, p. 739–749, 27 dez. 2016.

WANG, Y. et al. An Automatic Knee Osteoarthritis Diagnosis Method Based on Deep Learning: Data from the Osteoarthritis Initiative. **Journal of Healthcare Engineering**, v. 2021, 2021.

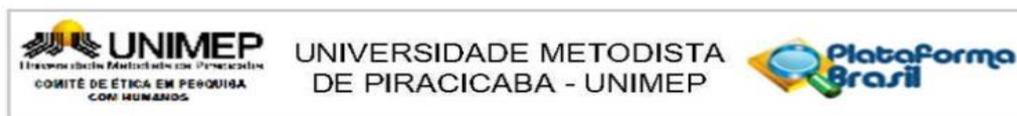
WENHAM, C. Y. J.; GRAINGER, A. J.; CONAGHAN, P. G. The role of imaging modalities in the diagnosis, differential diagnosis, and clinical assessment of peripheral joint osteoarthritis. **Osteoarthritis and cartilage**, v. 22, n. 10, p. 1692–1702, 1 out. 2014.

YEAP PM, ROBINSON P. Ultrasound Diagnostic and Therapeutic Injections of the Hip and Groin. **J Belg Soc Radiol**. 2017 Dec 16;101(Suppl 2):6. doi: 10.5334/jbr-btr.1371. PMID: 30498802; PMCID: PMC6251072.

ZHAO X, GONG W, LI X, YANG W, YANG D, LIU Z. Back Propagation Neural Network-Based Ultrasound Image for Diagnosis of Cartilage Lesions in Knee Osteoarthritis. **J Healthc Eng**. 2021 Jul 30;2021:2584291. doi: 10.1155/2021/2584291. PMID: 34373773; PMCID: PMC8349257.

## 8 ANEXOS

### 1. PARECER CONSUBSTANCIADO DO CEP



#### PARECER CONSUBSTANCIADO DO CEP

##### DADOS DO PROJETO DE PESQUISA

**Título da Pesquisa:** MÉTODOS DA INTELIGÊNCIA ARTIFICIAL APLICADOS NA ANÁLISE DO MOVIMENTO HUMANO

**Pesquisador:** GUANIS DE BARROS VILELA JUNIOR

**Área Temática:**

**Versão:** 1

**CAAE:** 33912120.9.0000.5507

**Instituição Proponente:** INSTITUTO EDUCACIONAL PIRACICABANO DA IGREJA METODISTA

**Patrocinador Principal:** Financiamento Próprio

##### DADOS DO PARECER

**Número do Parecer:** 4.126.546

##### Apresentação do Projeto:

Projeto adequadamente apresentado, contendo todos os dados necessários para sua análise.

##### Objetivo da Pesquisa:

Objetivos claros, coerentes com o desenho do projeto e exequíveis dentro do cronograma exposto.

##### Avaliação dos Riscos e Benefícios:

Os riscos aos sujeitos são mínimos e o projeto assegura o cuidado para reduzi-los. Os benefícios (diretos e indiretos) aos sujeitos estão presentes e superam os riscos.

##### Comentários e Considerações sobre a Pesquisa:

Destacam-se a relevância e as contribuições da pesquisa apresentada. As bases teóricas estão adequadas, a metodologia é coerente e a coleta de dados é adequada à proposta.

##### Considerações sobre os Termos de apresentação obrigatória:

O TCLE apresenta as informações necessárias. Acrescentar no início do texto a frase: Você está sendo convidado(a) a participar de um estudo na área da Ciências do Movimento Humano.

##### Conclusões ou Pendências e Lista de Inadequações:

O projeto está aprovado.

##### Considerações Finais a critério do CEP:

Este colegiado acolhe o parecer acima descrito e aprova o projeto.

Endereço: Rodovia do Açúcar, Km 156  
Bairro: Taquaral CEP: 13.400-911  
UF: SP Município: PIRACICABA  
Telefone: (19)3124-1513 Fax: (19)3124-1515 E-mail: comitedeetica@unimep.br