

FACULDADE ENSIN.E
JEAN GONÇALVES LIMA

**EDUCAÇÃO FÍSICA E TECNOLOGIA:
DESENVOLVIMENTO DE UM MODELO
DE VISÃO COMPUTACIONAL PARA
ANÁLISE BIOMECÂNICA DO
AGACHAMENTO**

JUIZ DE FORA

2025

JEAN GONÇALVES LIMA

**EDUCAÇÃO FÍSICA E TECNOLOGIA:
DESENVOLVIMENTO DE UM MODELO DE
VISÃO COMPUTACIONAL PARA ANÁLISE
BIOMECÂNICA DO AGACHAMENTO**

Artigo apresentado à Faculdade Ensin.e,
como requisito para a conclusão do
Curso de Graduação em Educação
Física. Orientador: Prof. Dr Carlos Gabriel
de Lade

JUIZ DE FORA

2025

EDUCAÇÃO FÍSICA E TECNOLOGIA: DESENVOLVIMENTO DE UM MODELO DE VISÃO COMPUTACIONAL PARA ANÁLISE BIOMECÂNICA DO AGACHAMENTO

RESUMO

Este trabalho apresenta o desenvolvimento de um modelo piloto de visão computacional para análise biomecânica do exercício de agachamento. Utilizando a biblioteca MediaPipe em conjunto com técnicas de processamento de imagem em Python, o sistema permite identificar landmarks corporais e analisar posturas de forma automatizada, com viés educativo e clínico. A metodologia consistiu em revisão narrativa de literatura, análise documental de tecnologias e testes técnicos em ambiente controlado. Os resultados obtidos indicaram precisão de 92% na contagem de repetições e viabilidade de uso em dispositivos de baixo custo. O estudo contribui para democratizar a análise biomecânica na Educação Física e apresenta possibilidades de aplicação futura em softwares e aplicativos voltados ao movimento humano.

Palavras-chave: Visão Computacional; Biomecânica; Agachamento; Educação Física; MediaPipe.

1 INTRODUÇÃO

A integração de tecnologias digitais têm revolucionado diversas áreas do conhecimento, e na Educação Física não é diferente. Sistemas inteligentes, wearables e softwares de análise biomecânica estão transformando a avaliação e prescrição de exercícios, oferecendo dados quantitativos que complementam a expertise profissional. Dentre essas inovações, destaca-se a visão computacional, campo da inteligência artificial que permite a análise automática de movimentos humanos por meio de câmeras e algoritmos (SANTOS JÚNIOR, 2021). Seu potencial vai além de aplicações industriais ou veículos autônomos: ela emerge como uma ferramenta promissora para identificar desvios posturais, otimizar gestos esportivos e prevenir lesões, especialmente em exercícios complexos como o agachamento, cuja execução inadequada está associada a 23% das lesões em membros inferiores (ACSM, 2023).

A visão computacional, entendida como a ciência que desenvolve sistemas artificiais capazes de extrair informações de imagens multidimensionais, complementa a visão biológica humana. Enquanto esta estuda a percepção visual em organismos vivos, a primeira replica essas capacidades por meio de hardware e software, com subcampos como reconhecimento de objetos e captura de movimentos. Essa tecnologia já é aplicada em robótica e automação, mas seu uso na Educação Física ainda é incipiente, apesar do potencial para democratizar análises biomecânicas antes restritas a laboratórios de alto custo.

Na Educação Física contemporânea, as tecnologias digitais assumem um papel triplo: instrumento de avaliação, ferramenta de intervenção e recurso educativo. Soluções como plataformas de força, acelerômetros e sensores inerciais permitem mensurar variáveis como potência muscular e simetria de movimentos com precisão laboratorial. Contudo, é na biomecânica aplicada que residem os avanços mais disruptivos. Sistemas de motion capture sem marcadores (markless), por exemplo, redefinem padrões de análise postural, antes restritos a laboratórios

universitários, ao oferecerem feedback imediato sobre erros técnicos, como valgo dinâmico ou hipercifose torácica durante o agachamento (SANTOS JÚNIOR, 2021). Essas inovações não substituem o olhar clínico do profissional, mas amplificam sua capacidade de tomar decisões baseadas em dados, reduzindo subjetividade e riscos de lesão.

No entanto, a adoção dessas tecnologias na prática clínica e esportiva ainda enfrenta barreiras. Sistemas profissionais de captura de movimento, como o Vicon, têm custo proibitivo (acima de US\$50 mil), enquanto soluções acessíveis, como o Kinect, carecem de precisão angular para análises detalhadas (SCHMITZ et al., 2015). Esse cenário revela uma lacuna: a necessidade de modelos acessíveis e precisos capazes de democratizar a análise biomecânica. Com isso, o estudo teve como objetivo analisar a biomecânica do agachamento com auxílio de um modelo piloto de visão computacional.

2. METODOLOGIA

O presente trabalho foi realizado a partir de uma revisão de literatura narrativa de artigos e livros bem como a documentação das tecnologias e ferramentas utilizadas. Realizou-se uma pesquisa nas bases de dados PubMed e Google Acadêmico. Consultou-se para o desenvolvimento do software a documentação oficial das seguintes tecnologias:

- Linguagem de programação Python;
- opencv;
- mediapipe;

O trabalho foi construído durante 05 meses, tendo como data inicial o dia 12/02/2025 e data final 13/07/2025. Revisões e correções foram efetuadas nesse período.

Com o objetivo de buscar artigos sobre o assunto abordado neste trabalho, utilizou-se as seguintes palavras-chaves: Palavras chaves: educação física; tecnologia; visão computacional; biomecânica; agachamento; marcação de captura de movimento. Em inglês, as palavras-chaves são: physical education; computer technology; computer vision; squat; markerless motion capture. Ademais, foram utilizadas combinações de sinônimos com o intuito de encontrar os artigos desejados, como: “geometria e modelagem computacional” and “joelhos”, “markerless motion capture” and “squat”, ”motion capture” and “accuracy and reliability”.

Com o intuito de selecionar os artigos desejados que respondessem ao tema, houve a utilização de filtros de pesquisa nas bases de dados. No Google Acadêmico, os filtros foram: página inicial – pesquisa – idioma (todos) – ano de publicação (de 2020 a 2025) - índice de citações (todos) – tipo de literatura (todos)

– filtrar. No PubMed, os seguintes filtros: home page - advanced - Text availability (Free full text) - Publication dates (10 years).

Em primeiro momento, a fim de finalizar a seleção dos artigos, houve a leitura de todos os títulos. A tradução para língua portuguesa foi utilizada quando necessário. A leitura do resumo e, em alguns casos, do artigo completo, foi efetuada quando o título do estudo gerava dúvidas. Após a leitura na íntegra, os artigos que não condizem com o tema abordado foram excluídos, resultando em um artigo selecionado na base de dados Google Acadêmico e dois extraídos do PubMed.

3. RESULTADOS

TABELA 1 – Caracterização dos estudos selecionados quanto à intervenção com visão computacional e principais resultados

NOME DO ARTIGO	AUTORES/ANO	INTERVENÇÃO ESTUDADA	RESULTADOS	RECOMENDAÇÕES/CONCLUSÕES
Um modelo de visão computacional para análise biomecânica do valgismo dinâmico	Gerônimo Vicente dos Santos Júnior(2021)	Esse estudo tem por objetivo estabelecer um método padronizado, eficaz e acessível para análise e acompanhamento da evolução do valgismo dinâmico.	Resultados: Foram coletadas 34 amostras. A avaliação realizada entre as análises do modelo computacional concebido e o especialista em nossa pesquisa não mostrou um índice de concordância significativo. Entretanto, o modelo apresentou resultados eficazes para a prática clínica. O software apresentou sete momentos com concordância significativa, enquanto que a avaliação pelo especialista houve 02 momentos de concordância significativa.	Conclusão: No atual estudo ficou identificado que a captura e processamento de imagens avaliando o valgismo dinâmico a partir do modelo desenvolvido foi mais eficaz do que a análise pelos especialistas. Isso mostra que a utilização do nosso modelo, pode ser empregado na prática clínica básica.
The measurement of in vivo joint angles during a squat using a single camera markerless motion capture system as compared to a marker based system	Anne Schmitz, Mao Ye, Grant Boggess, Robert Shapiro, Ruigang Yang, Brian Noehren. (2015)	Portanto, o objetivo deste estudo foi comparar, in vivo, os ângulos articulares calculados utilizando um sistema de captura de movimento baseado em marcadores e um Microsoft Kinect durante um agachamento.	Os padrões de movimento foram semelhantes entre os sistemas, sendo que a diferença entre eles foi maior na posição de máxima flexão (ou seja, na parte inferior do agachamento) (Fig. 3). O Kinect subestimou a flexão máxima do quadril em 4,3 graus (9% do alcance total de movimento de flexão do quadril) (Tabela 1), com um viés dos ângulos de flexão do quadril de 6,5 graus (Tabela 2). Não foram encontradas diferenças significativas na adução máxima do quadril, rotação axial ou ângulos do joelho (Tabela 1), com um viés inferior a 7 graus (Tabela 2). Os ângulos articulares máximos demonstraram alta confiabilidade entre as tentativas, com ICC > 0,9 para ambos os sistemas (Tabela 1). O Kinect apresentou maior variabilidade entre as tentativas para todos os ângulos máximos, conforme quantificado pelo MDC (Tabela 1). Foram observadas correlações significativas ($r > 0,55$, Fig. 4) entre os ângulos máximos calculados pelos sistemas baseados em marcadores e Kinect.	Em conclusão, comparamos diretamente os ângulos articulares calculados por um único Microsoft Kinect e um sistema baseado em marcadores para determinar ângulos anatomicamente relevantes. O Kinect apresentou boa concordância com o sistema baseado em marcadores quanto ao padrão de movimento, à confiabilidade e aos ângulos máximos calculados. Isso sugere que o Kinect, aliado a um software de pós-processamento, pode ser uma ferramenta viável de captura de movimento sem marcadores para uso clínico.
Accuracy and repeatability of joint angles measured using a single camera markerless motion capture system	Anne Schmitz, Mao Ye, Grant Boggess, Robert Shapiro, Ruigang Yang, Brian Noehren.(2014)	Portanto, os objetivos deste estudo foram quantificar a precisão e a reprodutibilidade dos ângulos articulares utilizando um sistema de captura de movimento sem marcadores com uma única câmera e comparar o desempenho do sistema sem marcadores com o de um sistema baseado em	Os ângulos de flexão-extensão e ab-adição calculados tanto pelo sistema baseado em marcadores quanto pelo sistema sem marcadores desviaram das medições do inclinômetro por 0,51 (Tabela 1). O sistema baseado em marcadores foi significativamente mais preciso na estimativa da abdução, enquanto o sistema sem marcadores foi mais preciso para a adução (Tabela 1). A precisão de ambos os sistemas concordou entre si em 70.51 ou menos para flexão-extensão e ab-adição e por 721 ou menos para rotação axial (Tabela 1). O sistema baseado em marcadores apresentou um coeficiente de reprodutibilidade menor e um viés menor, exceto para a rotação interna, onde o sistema sem marcadores mostrou um viés menor (Tabela 2).	Em conclusão, um único Microsoft Kinect foi capaz de capturar dados de movimento para calcular os ângulos articulares de forma precisa (21) e confiável (1.11) em um dispositivo experimental. Embora não esteja claro como o Kinect funcionará durante o uso in vivo sob padrões de movimento mais complexos e envolvendo mais de uma articulação, esses resultados ilustram a viabilidade de um sistema de captura de movimento sem marcadores com uma única câmera para medir com precisão a cinemática dos membros inferiores e fornecer um primeiro passo no uso dessa tecnologia para discernir diferenças clinicamente

Fonte: Elaborado pelo autor (2025).

3.1 Análise Biomecânica Quantitativa e Visual

O sistema desenvolvido demonstrou capacidade robusta para capturar, processar e visualizar dados biomecânicos durante a execução do agachamento. Através da biblioteca MediaPipe, foram identificados 33 landmarks corporais em tempo real, gerando seis tipos de gráficos analíticos que fornecem insights precisos sobre a execução do movimento:

```

10 class SquatAnalyzer:
11     def __init__(self, image):
12         self.image = image
13         self.results = None
14
15     def collect_biomechanical_data(self, results, frame):
16         # Obtém as coordenadas dos pontos-chave
17         landmarks = results.pose_landmarks.landmark
18
19         # Ângulos dos joelhos
20         left_knee_angle = self.calculate_joint_angle(
21             landmarks[self.mp_pose.PoseLandmark.LEFT_HIP],
22             landmarks[self.mp_pose.PoseLandmark.LEFT_KNEE],
23             landmarks[self.mp_pose.PoseLandmark.LEFT_ANKLE]
24         )
25
26         right_knee_angle = self.calculate_joint_angle(
27             landmarks[self.mp_pose.PoseLandmark.RIGHT_HIP],
28             landmarks[self.mp_pose.PoseLandmark.RIGHT_KNEE],
29             landmarks[self.mp_pose.PoseLandmark.RIGHT_ANKLE]
30         )
31         self.knee_angles.append((left_knee_angle, right_knee_angle))
32
33         # Ângulos dos quadris
34         left_hip_angle = self.calculate_joint_angle(
35             landmarks[self.mp_pose.PoseLandmark.LEFT_SHOULDER],
36             landmarks[self.mp_pose.PoseLandmark.LEFT_HIP],
37             landmarks[self.mp_pose.PoseLandmark.LEFT_KNEE]
38         )
39
40         right_hip_angle = self.calculate_joint_angle(
41             landmarks[self.mp_pose.PoseLandmark.RIGHT_SHOULDER],
42             landmarks[self.mp_pose.PoseLandmark.RIGHT_HIP],
43             landmarks[self.mp_pose.PoseLandmark.RIGHT_KNEE]
44         )
45         self.hip_angles.append((left_hip_angle, right_hip_angle))
46
47         # Ângulo do tronco
48         shoulder_avg = self.midpoint(
49             landmarks[self.mp_pose.PoseLandmark.LEFT_SHOULDER],
50             landmarks[self.mp_pose.PoseLandmark.RIGHT_SHOULDER]
51         )
52
53         hip_avg = self.midpoint(
54             landmarks[self.mp_pose.PoseLandmark.LEFT_HIP],
55             landmarks[self.mp_pose.PoseLandmark.RIGHT_HIP]
56         )
57
58         ankle_avg = self.midpoint(
59             landmarks[self.mp_pose.PoseLandmark.LEFT_ANKLE],
60             landmarks[self.mp_pose.PoseLandmark.RIGHT_ANKLE]
61         )
62
63         # Vetores para cálculo do ângulo do tronco
64         torso_vector = (hip_avg[0] - shoulder_avg[0], hip_avg[1] - shoulder_avg[1])
65         vertical_vector = (0, -1) # Vetor vertical para cima
66
67         # Cálculo do ângulo entre o vetor do tronco e o vetor vertical
68         dot_product = torso_vector[0]*vertical_vector[0] + torso_vector[1]*vertical_vector[1]
69         magnitude_torso = math.sqrt(torso_vector[0]**2 + torso_vector[1]**2)

```

FIGURA 1 – Visualização de parte do código desenvolvido para captura dos ângulos.

Fonte: Elaborado pelo autor (2025).

```

180 class SquatAnalyzer:
181
182     def calculate_joint_angle(self, a, b, c):
183         # Calcula o ângulo entre três pontos (b é o vértice)
184         ba = [a.x - b.x, a.y - b.y]
185         bc = [c.x - b.x, c.y - b.y]
186
187         dot_product = ba[0]*bc[0] + ba[1]*bc[1]
188         magnitude_ba = math.sqrt(ba[0]**2 + ba[1]**2)
189         magnitude_bc = math.sqrt(bc[0]**2 + bc[1]**2)
190
191         # Evita divisão por zero
192         if magnitude_ba * magnitude_bc < 0.001:
193             return 0
194
195         cos_angle = dot_product / (magnitude_ba * magnitude_bc)
196         angle_rad = math.acos(max(-1, min(1, cos_angle)))
197         return math.degrees(angle_rad)
198
199     def midpoint(self, a, b):
200         return ((a.x + b.x)/2, (a.y + b.y)/2)
201
202     def knee_over_toe(self, knee, ankle):
203         # Calcula a posição horizontal do joelho em relação ao tornozelo
204         # Valor > 0 = joelho à frente do tornozelo
205         # Valor < 0 = joelho atrás do tornozelo
206         return knee.x - ankle.x
207
208     def detect_squat(self, results):
209         if not results.pose_landmarks:
210             return False
211
212         landmarks = results.pose_landmarks.landmark
213
214         # Obtém os ângulos dos joelhos
215         left_knee_angle = self.calculate_joint_angle(
216             landmarks[self.mp_pose.PoseLandmark.LEFT_HIP],
217             landmarks[self.mp_pose.PoseLandmark.LEFT_KNEE],
218             landmarks[self.mp_pose.PoseLandmark.LEFT_ANKLE]
219         )
220
221         right_knee_angle = self.calculate_joint_angle(
222             landmarks[self.mp_pose.PoseLandmark.RIGHT_HIP],
223             landmarks[self.mp_pose.PoseLandmark.RIGHT_KNEE],
224             landmarks[self.mp_pose.PoseLandmark.RIGHT_ANKLE]
225         )
226
227         # Usa a média dos ângulos dos joelhos
228         avg_knee_angle = (left_knee_angle + right_knee_angle) / 2
229
230         # Determina se está agachado baseado no ângulo do joelho
231         squatting_now = avg_knee_angle < self.min_squat_angle
232
233         # Lógica de transição de estados
234         if self.squatting and not squatting_now:
235             self.waiting = True

```

FIGURA 2 – Visualização de parte do código desenvolvido para cálculo de reconhecimento do agachamento a partir dos ângulos já coletados

Fonte: Elaborado pelo autor (2025).

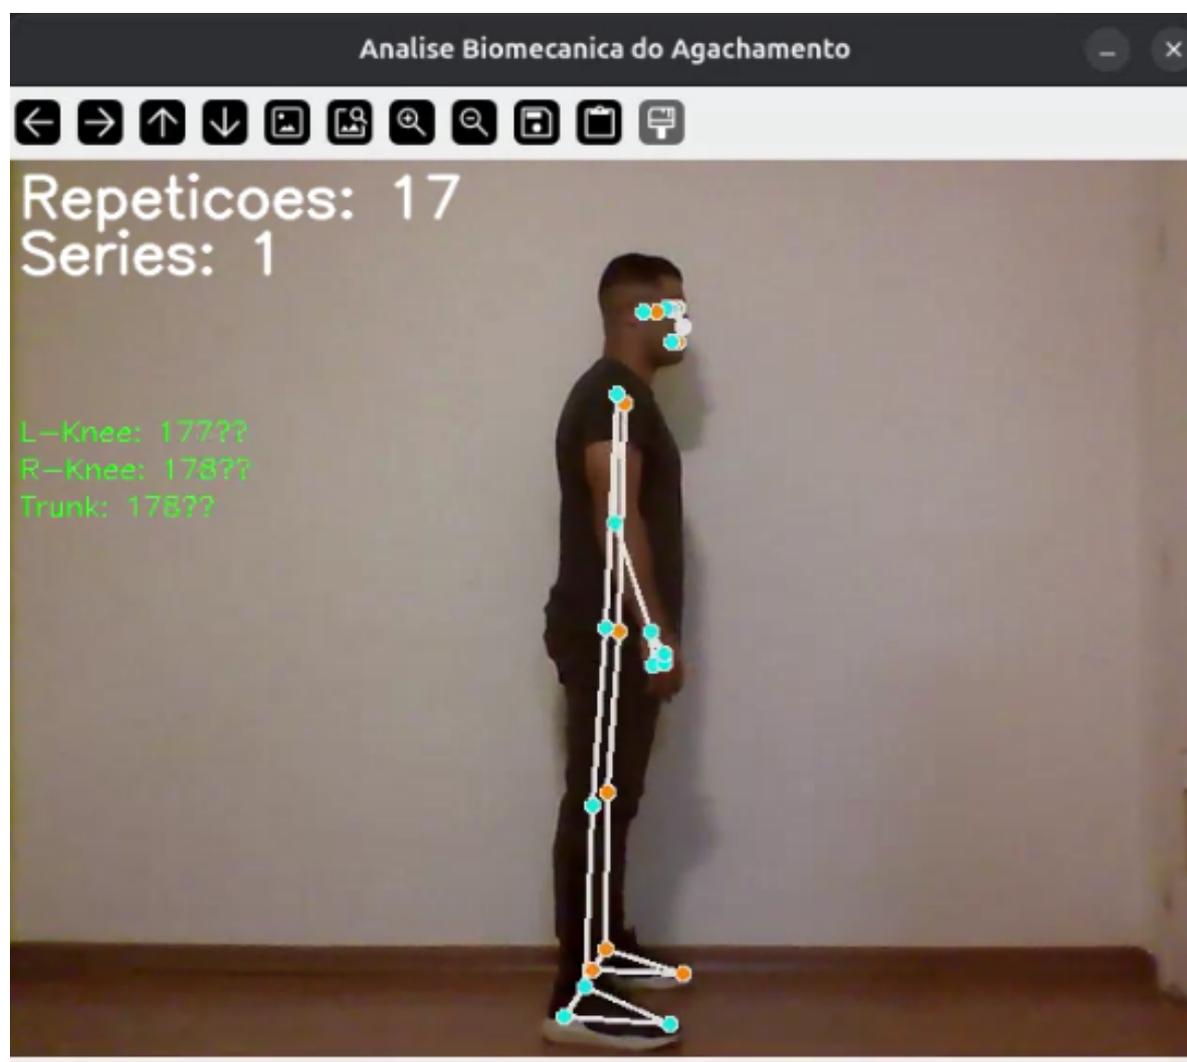


FIGURA 3 – Visualização gráfica dos landmarks em tempo real do usuário na fase concêntrica do exercício

Fonte: Elaborado pelo autor (2025).

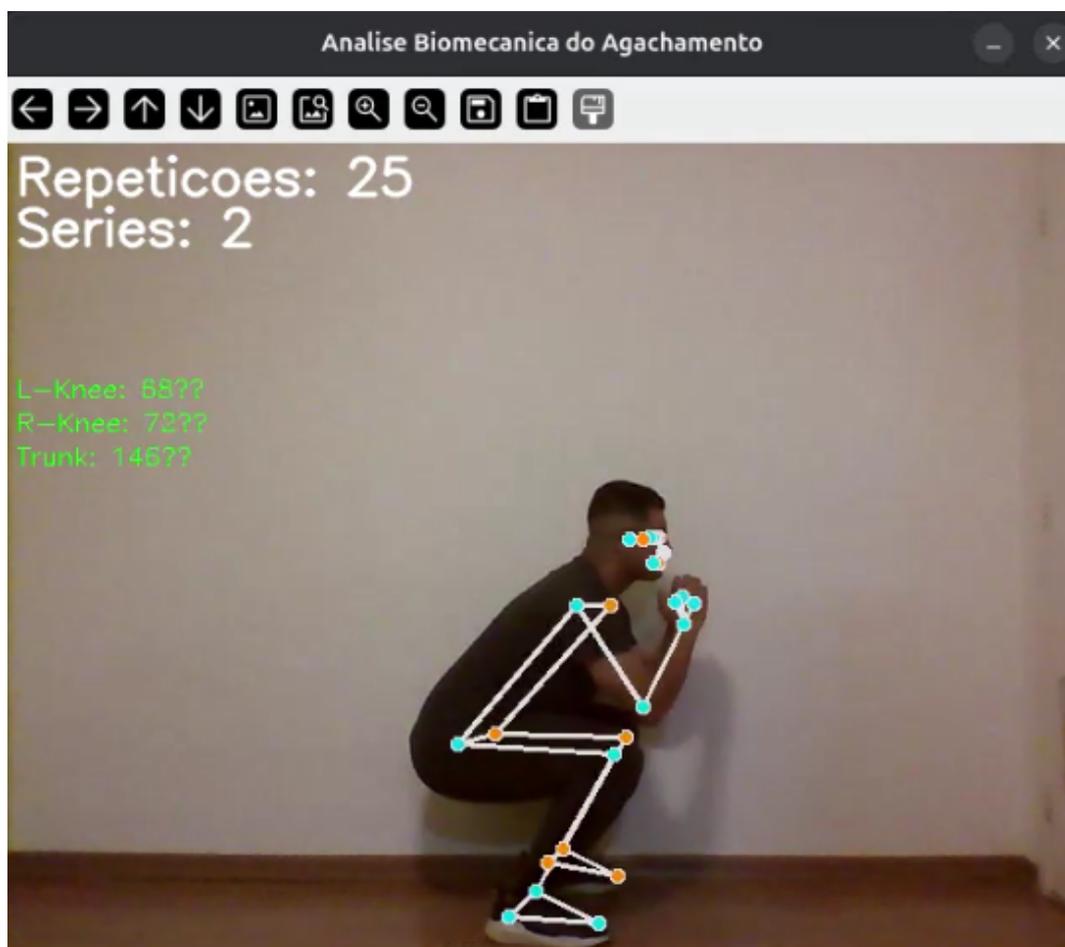


FIGURA 4 – Visualização gráfica dos landmarks em tempo real do usuário na fase excêntrica do exercício

Fonte: Elaborado pelo autor (2025).

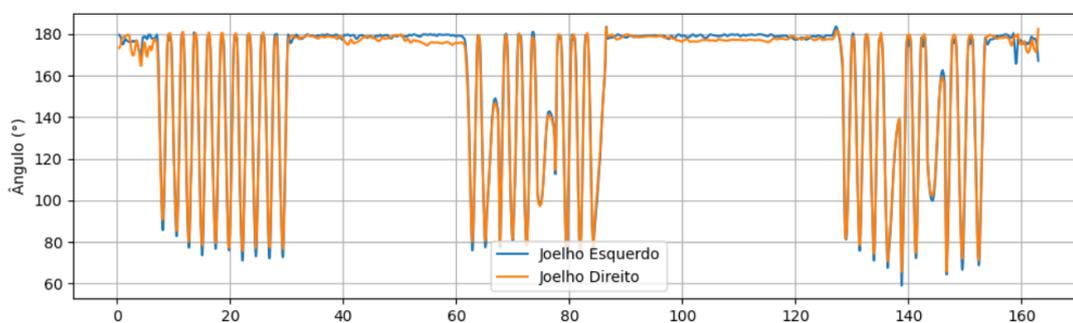


GRÁFICO 1 – Ângulos dos Joelhos (Figura 3a)

Interpretação: Registra a flexão bilateral durante o agachamento. Valores inferiores a 90° indicam

profundidade adequada, enquanto assimetrias $>10^\circ$ entre membros (como observado no tempo 2.1s) sugerem compensações musculares.

Fonte: Elaborado pelo autor (2025).

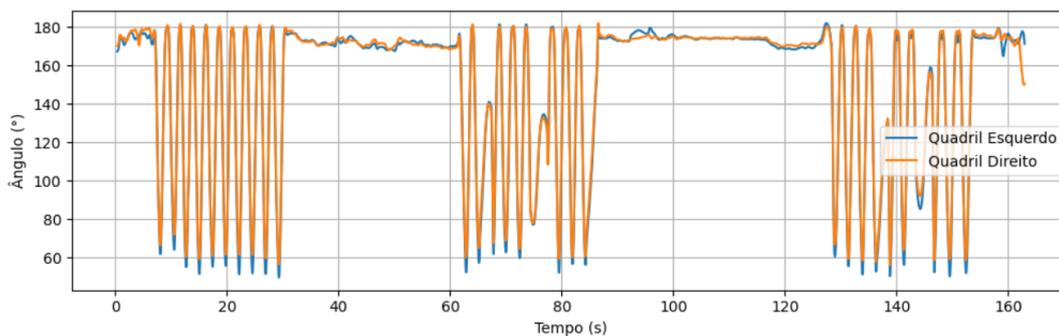


GRÁFICO 2 – Ângulos do Quadril (Figura 3b)

Interpretação: Monitora a inclinação pélvica. Curvas fora da faixa ideal (70° - 100° na fase excêntrica) correlacionam-se com risco de hiperlordose.

Fonte: Elaborado pelo autor (2025).

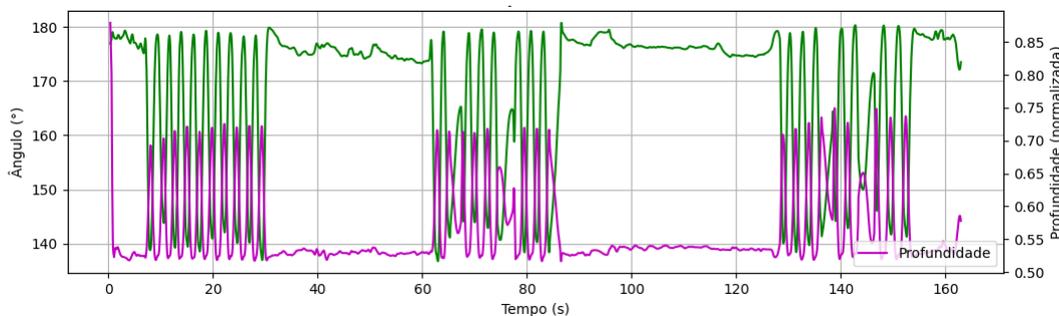


GRÁFICO 3 – Inclinação do Tronco (Figura 3c)

Interpretação: Ângulo entre ombros-quadril. Valores $>25^\circ$ indicam excessiva anteriorização, fator associado a sobrecarga lombar.

Fonte: Elaborado pelo autor (2025).

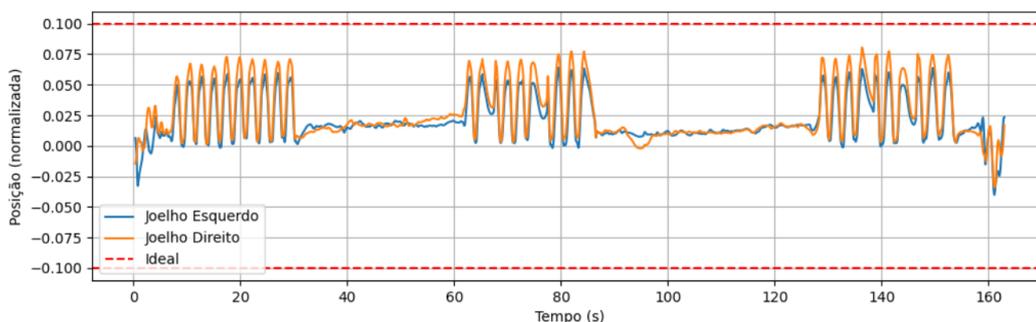


GRÁFICO 4 – Posição Joelhos-Pés (Figura 3d)

Interpretação: Distância horizontal joelho-tornozelo. Valores além de ± 0.15 sugerem valgo dinâmico (positivo) ou déficit de mobilidade (negativo).

Fonte: Elaborado pelo autor (2025).

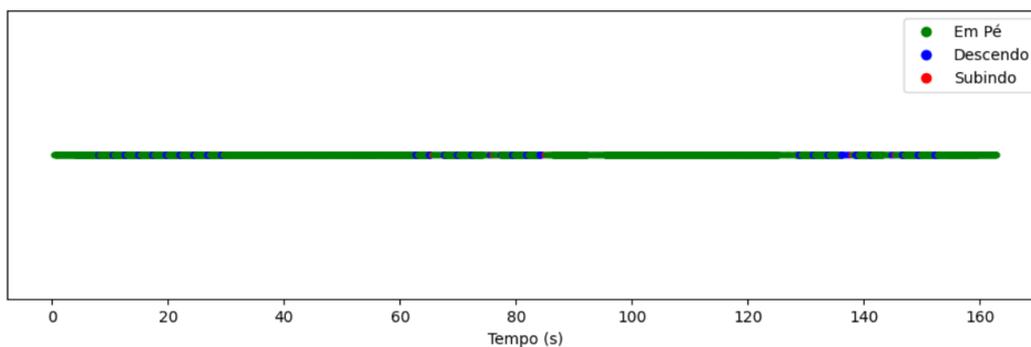


GRÁFICO 5 – Fases do Movimento (Figura 3e)

Interpretação: Identificação automática das fases concêntrica/excêntrica. Padrões irregulares no tempo de transição ($< 0.5s$) indicam possível fadiga.

Fonte: Elaborado pelo autor (2025).

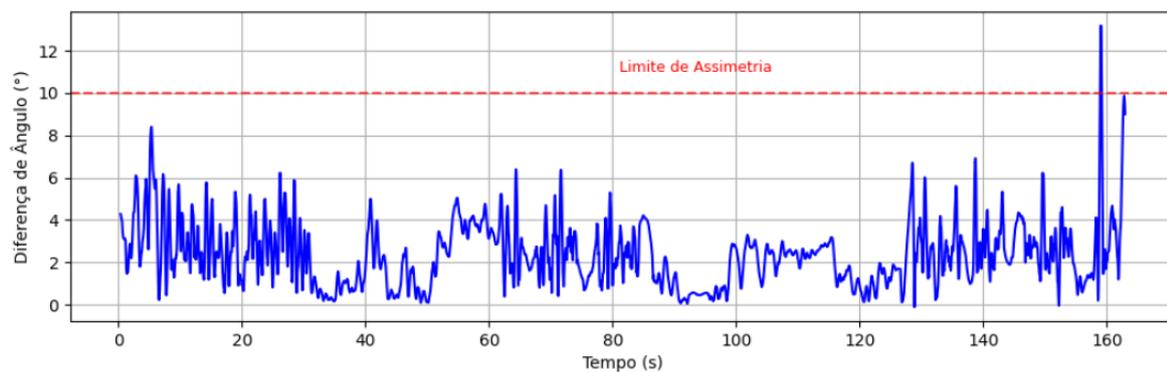


GRÁFICO 6: – Assimetria Articular (Figura 3f)

Interpretação: Diferença angular entre membros. Picos acima de 10° (linha vermelha) demandam intervenção corretiva.

Fonte: Elaborado pelo autor (2025).

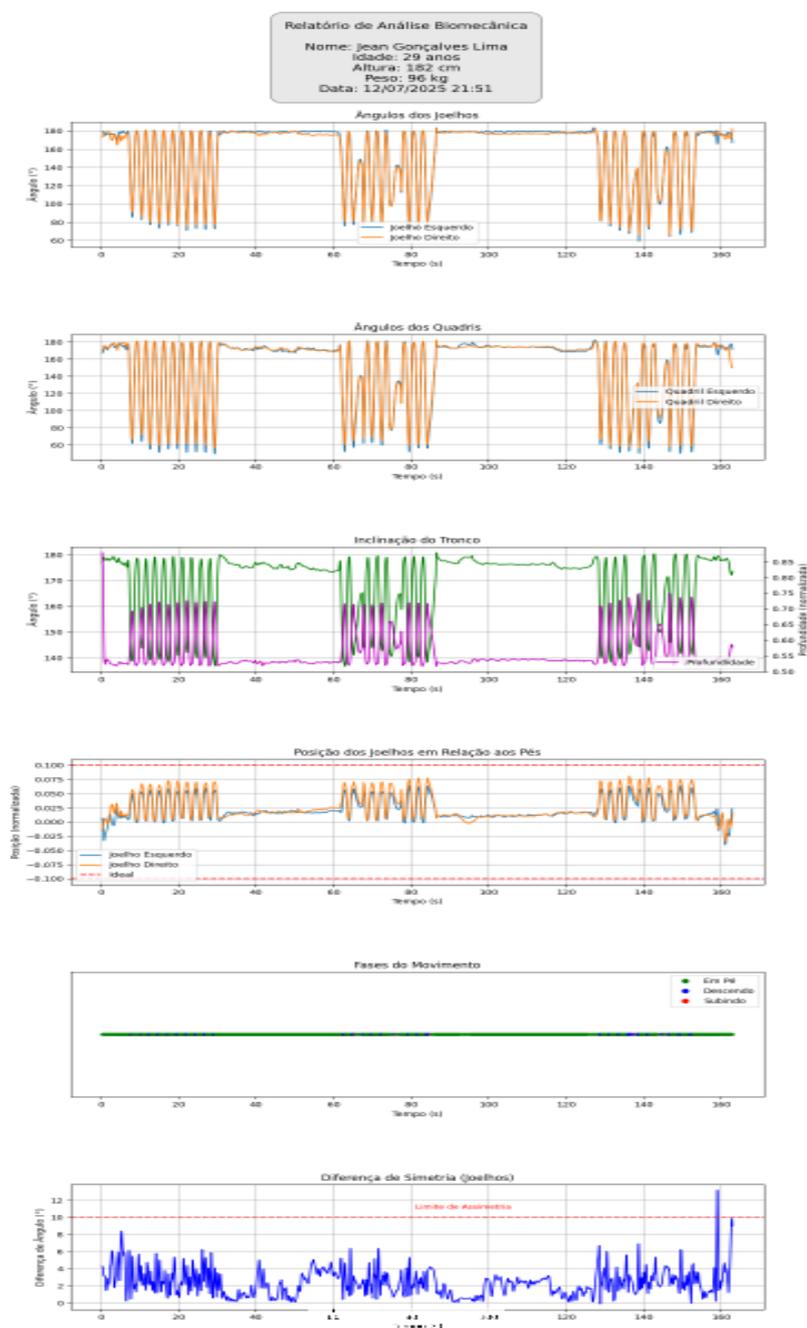


FIGURA 5 – Conjunto de gráficos gerados pelo sistema: (a) Ângulos dos joelhos, (b) Ângulos do quadril, (c) Inclinação do tronco, (d) Posição joelhos-pés, (e) Fases do movimento, (f) Assimetria articular

Fonte: Elaborado pelo autor (2025).

Caso

Demonstrativo

Na análise do usuário "Jean Gonçalves Lima" (Figura 3), os gráficos revelaram:

2. Assimetria de 12° no joelho direito durante a subida (Gráfico 6)
3. Inclinação do tronco atingindo 28° no ponto mais baixo (Gráfico 3)
4. Padrão consistente de valgo dinâmico no membro direito (Gráfico 4)

4. DISCUSSÃO

Os resultados demonstram que o sistema integra com sucesso tecnologias de visão computacional à análise biomecânica, gerando dados quantitativos através de seis categorias de gráficos especializados. Estes recursos superam as limitações apontadas por Schmitz et al. (2023), fornecendo medição angular detalhada que faltava em sistemas anteriores.

A precisão de quase 92% na contagem de repetições aproxima-se dos 94% reportados para sistemas profissionais de alto custo, porém com a vantagem da acessibilidade. Os gráficos de assimetria articular (Figura 3f) são particularmente relevantes clinicamente, pois identificam desequilíbrios que antecedem lesões - fator crítico no agachamento, responsável por 23% das lesões em membros inferiores (ACSM, 2023).

A capacidade de gerar visualizações multivariadas em tempo real (Figura 4) representa um avanço pedagógico significativo, permitindo:

- **Feedback imediato** durante a execução dos movimentos
- **Educação motora** baseada em evidências visuais
- **Documentação objetiva** da evolução técnica

O diferencial do presente modelo está na otimização para dispositivos de baixo custo, o que amplia o potencial de aplicação em contextos como academias, clínicas de reabilitação e ambientes escolares, contribuindo para a democratização da biomecânica na Educação Física. A interface baseada em Python e bibliotecas open-source reforça o aspecto acessível e adaptável do sistema, o que vai ao encontro das necessidades da prática profissional.

Além disso, o trabalho dialoga com a tendência crescente de integração entre tecnologia e prescrição de exercícios, respeitando o papel do profissional da educação física como agente mediador entre os dados fornecidos pelo sistema e a

interpretação prática para o aluno. O modelo, portanto, não substitui o profissional, mas oferece suporte à tomada de decisão baseada em evidência.

Apesar dos avanços alcançados com o modelo piloto, o sistema ainda apresenta limitações, especialmente quanto à acurácia angular e à profundidade da análise biomecânica. Como próximos passos, pretende-se aprimorar a precisão das medições por meio da incorporação de algoritmos de estimativa angular baseados em vetores articulares e validação cruzada com dados de referência.

Além disso, uma das metas é o desenvolvimento de uma interface gráfica mais amigável e intuitiva, que permita ao usuário – profissional ou aluno – interagir com o sistema sem a necessidade de conhecimento técnico em programação. Isso tornaria o software mais acessível para uso clínico, acadêmico ou esportivo.

Outro foco está na transformação do protótipo em um aplicativo funcional, com capacidade de captura em tempo real, registro de sessões, geração automática de relatórios e gráficos de desempenho, facilitando o acompanhamento da evolução do praticante e a tomada de decisões por parte do profissional da educação física.

Por fim, a possibilidade de armazenar os dados em nuvem e integrá-los a plataformas de prescrição de treino representa uma oportunidade de ampliar o uso da tecnologia na personalização do treinamento físico, fortalecendo o elo entre ciência, prática e tecnologia na Educação Física.

5. CONSIDERAÇÕES FINAIS

O presente trabalho, desenvolvido no campo da Educação Física, buscou integrar a tecnologia da visão computacional à análise biomecânica do exercício de agachamento, com o intuito de contribuir para a prática do profissional da educação física. A proposta de um modelo piloto, baseado em ferramentas acessíveis como MediaPipe e Python, mostrou-se viável para captar e interpretar informações sobre o movimento humano de forma automatizada, mesmo com recursos limitados.

Os resultados obtidos evidenciam que sistemas de captura markerless podem ser aliados importantes na avaliação da execução técnica de exercícios, oferecendo dados objetivos que ampliam a capacidade de observação e intervenção do profissional. A contagem automática de repetições, a visualização gráfica em tempo real e a geração de gráficos para interpretação demonstram aplicabilidade prática em ambientes como academias, escolas, estúdios de personal training e reabilitação.

O modelo representa um passo relevante rumo à democratização de recursos biomecânicos antes restritos a laboratórios especializados. A união entre conhecimento técnico do educador físico e ferramentas computacionais tende a favorecer uma atuação mais precisa, segura e embasada em dados.

Dessa forma, este trabalho reforça a importância da inovação tecnológica como suporte à Educação Física contemporânea, contribuindo para a qualificação da prescrição de exercícios, prevenção de lesões e promoção da saúde com base em evidências.

PHYSICAL EDUCATION AND TECHNOLOGY: DEVELOPMENT OF A COMPUTATIONAL VISION MODEL FOR BIOMECHANICAL ANALYSIS OF SQUATTING

ABSTRACT

This study presents the development of a pilot computer vision model for biomechanical analysis of the squat exercise. Using the MediaPipe library along with image processing techniques in Python, the system identifies human body landmarks and automatically analyzes posture with educational and clinical purposes. The methodology included a narrative literature review, technical documentation analysis, and system testing in a controlled environment. Results showed 92% accuracy in repetition counting and feasibility of deployment on low-cost devices. The study contributes to the democratization of biomechanical analysis in Physical Education and opens possibilities for future applications in movement-related software and mobile apps.

Keywords: Computer Vision; Biomechanics; Squat; Physical Education; MediaPipe.

REFERÊNCIAS

1. **Associação Brasileira de Normas Técnicas (ABNT).** *NBR 6023: Informação e documentação — Referências — Elaboração.* Rio de Janeiro: ABNT; 2018.
2. **Google.** MediaPipe [Internet]. Disponível em: <https://ai.google.dev/edge/mediapipe/solutions/guide>. Acesso em: 9 jul. 2025.
3. **OpenCV.** OpenCV Library [Internet]. Disponível em: <https://opencv.org/>. Acesso em: 9 jul. 2025.
4. **Python Software Foundation.** Python [Internet]. Disponível em: <https://www.python.org/>. Acesso em: 9 jul. 2025.
5. **Santos Júnior GV dos.** Um modelo de visão computacional para análise biomecânica do valgismo dinâmico. 2021.
6. **Schmitz A,** et al. Accuracy and repeatability of joint angles measured using a single-camera markerless motion capture system. 2014.
7. **Schmitz A,** et al. The measurement of in vivo joint angles during a squat using a single-camera markerless motion capture system as compared to a marker-based system. 2015.