

Segmentação Automática de Regiões de Interesse em Radiografias da Mão Utilizando YOLOv10

Automatic Segmentation of Regions of Interest in Hand Radiographs Using YOLOv10

¹Bianca Bertoldo de Oliveira, ²Milena Bueno Pereira Carneiro

¹Mestrado em Engenharia Elétrica no Programa de Pós-graduação em Engenharia Elétrica – Universidade Federal de Uberlândia (bertoldoobianca@gmail.com)

²Professora Associada do Programa de Graduação em Engenharia Eletrônica e de Telecomunicações da Faculdade de Engenharia Elétrica – Universidade Federal de Uberlândia (milena@ufu.br)

RESUMO: O objetivo deste trabalho é apresentar uma metodologia para a segmentação automática de regiões anatômicas de interesse em radiografias da mão utilizando o modelo de detecção de objetos YOLOv10. A segmentação foi proposta como etapa de pré-processamento de um sistema de avaliação automatizada da idade óssea, permitindo que análises subsequentes operem apenas sobre regiões clinicamente relevantes (articulação, metacarpo e carpo), reduzindo o custo computacional associado ao processamento de imagens completas. Para o treinamento do modelo, 204 imagens foram anotadas manualmente, divididas em conjuntos de treino e validação e enriquecidas por técnicas de aumento de dados. O modelo YOLOv10s foi avaliado por meio das métricas de precisão, recall e acurácia geral. Os resultados experimentais mostraram desempenho superior a 96% em validação e acurácia global de 99,7% sobre a base completa de 18.787 imagens, com tempo médio de inferência de 0,11 segundos por imagem em CPU, demonstrando a viabilidade prática da abordagem para aplicações em ambientes clínicos e sistemas de apoio ao diagnóstico médico.

Palavras Chave: Aprendizado profundo. Detecção de objetos. Idade óssea. Redes neurais convolucionais. Processamento digital de imagens.

ABSTRACT: The objective of this paper is to present a methodology for the automatic segmentation of anatomical regions of interest in hand radiographs using the YOLOv10 object detection model. The segmentation was proposed as a preprocessing step for an automated bone age assessment system, allowing subsequent analyses to operate only on clinically relevant regions (joint, metacarpus, and carpus), thereby reducing the computational cost associated with processing full images. For model training, 204 images were manually annotated, divided into training and validation sets, and enriched using data augmentation techniques. The YOLOv10s model was evaluated using precision, recall, and overall accuracy metrics. The experimental results showed performance above 96% on the validation set and a global accuracy of 99.7% on the complete dataset of 18,787 images, with an average inference time of 0.11 seconds per image on CPU, demonstrating the practical feasibility of the proposed approach for clinical applications and computer-aided diagnostic systems.

Keywords: Deep learning. Object detection. Bone age. Convolutional neural networks. Digital image processing.

Recebido em:
07/06/2026
Publicado em:
06/07/2026

1. INTRODUÇÃO

A avaliação da idade óssea é uma prática clínica fundamental e rotineira na pediatria, utilizada para monitorar a maturação esquelética de crianças e adolescentes (Satoh, 2015). A discrepância entre a idade óssea de um paciente e sua idade cronológica é um indicador diagnóstico vital para a investigação de uma variedade de condições, incluindo distúrbios de crescimento e desordens endócrinas, sendo considerada anormal quando se desvia em mais de 20% (Melmed et al., 2015). Historicamente, essa avaliação é realizada manualmente por

radiologistas mediante a inspeção visual de radiografias da mão e do punho esquerdos, com auxílio dos métodos clássicos de Greulich e Pyle (1959) e Tanner et al. (1975).

Apesar da utilidade clínica estabelecida, esses métodos manuais são dependentes da experiência do radiologista, consomem tempo clínico e estão sujeitos a uma variabilidade interobservador e intraobservador significativa (Thodberg et al., 2008). Neste contexto, a evolução das redes neurais profundas oferece um potencial transformador para a radiologia diagnóstica, fornecendo ferramentas objetivas, rápidas e reprodutíveis (Litjens et al., 2017).


Em fluxos de aprendizado profundo aplicados à estimativa da idade óssea, a etapa de segmentação das regiões anatômicas relevantes é frequentemente fundamental, pois nas radiografias o fundo da imagem não fornece informações úteis para a estimativa e o padrão de ossificação tende a ser semelhante em diferentes partes da mão, tornando algumas informações visuais redundantes. Trabalhos como os de Iglovikov et al. (2018) e Guo et al. (2022) demonstraram que abordagens regionalizadas, baseadas em centros de ossificação, podem superar análises holísticas da imagem completa. Entretanto, embora modelos de detecção como o You Only Look Once (YOLO) (Redmon et al., 2016) sejam amplamente usados em visão computacional, sua aplicação específica para a localização automática de regiões de interesse no contexto da idade óssea ainda é escassa, com a maioria dos trabalhos optando por modelos de segmentação convencionais como U-Net (Chu et al., 2018) ou DeepLab (Zulkifley et al., 2021).

O presente trabalho propõe a utilização do modelo YOLOv10 para a segmentação automática de três regiões anatômicas (articulação interfalangeana, ossos metacarvais e ossos do carpo) como etapa de pré-processamento em um pipeline de avaliação da idade óssea. A motivação central é viabilizar o processamento subsequente apenas sobre as áreas clinicamente relevantes, reduzindo o custo computacional associado ao processamento de imagens inteiras de alta resolução e direcionando a inferência da idade óssea para regiões de maior conteúdo discriminativo. Este artigo apresenta a metodologia de anotação, treinamento e avaliação do modelo de segmentação, bem como os resultados quantitativos obtidos sobre uma base composta por mais de 18 mil radiografias.

2. MATERIAIS E MÉTODOS

A metodologia adotada para a segmentação automática das regiões de interesse foi organizada em três etapas principais: (i) preparação e pré-processamento das imagens; (ii) anotação manual de uma amostra criteriosamente selecionada do conjunto de dados; e (iii) treinamento, validação e aplicação do modelo YOLOv10 sobre toda a base. A Figura 1 apresenta uma visão geral do fluxo desenvolvido, evidenciando as etapas em que o YOLO atua como mecanismo de localização das regiões anatômicas que alimentam as análises subsequentes.

Figura 1 – Fluxograma da metodologia proposta.



2.1 Banco de dados

Para o desenvolvimento do trabalho foram utilizadas duas bases de dados públicas distintas. A base da Radiological Society of North America (RSNA), composta por 12.611 radiografias da mão obtidas em hospitais pediátricos dos Estados Unidos (RSNA, 2017); e a Radiological Hand Pose Estimation (RHPE) (Escobar et al., 2019), composta por 6.204 radiografias provenientes de uma população com características distintas, contribuindo para uma melhor capacidade de generalização. Em ambas, as imagens apresentam elevada variabilidade de resolução, indo de 800×1.011 até 8.480×6.960 pixels, e foram adquiridas com diferentes equipamentos e protocolos. As Figuras 2 e 3 apresentam exemplos representativos das duas bases, evidenciando a heterogeneidade de posicionamento, contraste e qualidade das imagens.

Figura 2 – Exemplos de radiografias da base RSNA.






Figura 3 – Exemplos de radiografias da base RHPE.



O conjunto agregado totaliza 18.787 imagens. A Figura 4 apresenta a distribuição das idades ósseas das bases unidas, indicando concentração maior de amostras em faixas etárias intermediárias e menor representatividade nos extremos.


Figura 4 – Distribuição das idades ósseas no conjunto agregado RSNA + RHPE.



2.2 Pré-processamento

Os valores dos pixels das radiografias são afetados por parâmetros técnicos da aquisição, pela orientação da mão e pela luminosidade da região registrada. Devido à natureza multi-institucional dos dados, observa-se ampla variação de intensidade não relacionada às características estruturais de interesse. Para reduzir essas variações, foi aplicada a técnica de *Contrast Limited Adaptive Histogram Equalization* (CLAHE), no qual o contraste é controlado por meio do recorte do histograma em um valor predefinido antes do cálculo da função de distribuição acumulada (Shome e Vadali, 2011), normalizando os tons de cinza e realçando detalhes ósseos relevantes para as etapas seguintes. A Figura 5 ilustra o efeito do CLAHE em diferentes radiografias.


Figura 5 – Exemplos de radiografias disponíveis na base. a), b) e c) Imagens originais. d), e) e f) Correção com CLAHE.



2.3 Anotação das regiões de interesse

Selecionar de forma adequada a região da imagem utilizada para inferência é fundamental, pois contribui para eliminar variações visuais que não têm relação com a idade óssea. As regiões escolhidas foram três: (i) a articulação entre a falange média e proximal, (ii) os quatro ossos do metacarpo localizados na palma da mão e (iii) os ossos do carpo. Foram rotuladas manualmente 204 imagens com auxílio da plataforma *Computer Vision Annotation Tool* (CVAT), selecionadas de forma criteriosa para representar a diversidade existente no banco, contemplando variações de posicionamento, brilho, contraste, proporção e presença de bordas e identificadores de exame. A Figura 6 apresenta a interface utilizada e as três regiões delimitadas em uma das imagens da base.

Figura 6 – Interface do CVAT durante a anotação das três regiões de interesse.



As anotações foram exportadas em formato compatível com o YOLOv10. Cada imagem recebe um arquivo de rótulo em formato .txt, contendo uma linha por região anotada, composta por cinco valores: classe, coordenadas x e y do centro da caixa delimitadora, largura e altura, todos normalizados em relação ao tamanho total da imagem.

2.4 Configuração do treinamento

O conjunto anotado foi dividido em 70% para treinamento e 30% para validação. Quando treinados com conjuntos reduzidos, a capacidade de generalização do modelo é prejudicada. O *Data Augmentation* consiste em ampliar artificialmente o conjunto de treinamento por meio da criação de cópias transformadas das amostras originais (Wang et al., 2024). Para ampliar a variabilidade e tornar o modelo mais robusto, foram geradas duas novas versões de cada imagem original aplicando aleatoriamente: (i) espelhamento horizontal; (ii) rotação no intervalo de -10° a 10° ; (iii) variação de escala de até 10%; e (iv) modificações de brilho ($\pm 20\%$), contraste ($\pm 10\%$) e saturação ($\pm 20\%$).

O YOLOv10 disponibiliza cinco versões escalonadas (n, s, m, l e x), que diferem em profundidade da rede, número de canais por camada, número total de parâmetros e uso de memória. Optou-se pela versão pequena (s), que oferece bom equilíbrio entre desempenho computacional e precisão na detecção, sendo adequada para conjuntos de tamanho moderado (Raiaan et al., 2024). O treinamento foi conduzido localmente em uma GPU NVIDIA GeForce GTX 1060 6GB, com os hiperparâmetros listados na Tabela 1.

Tabela 1 – Hiperparâmetros do treinamento do YOLOv10s.

Hiperparâmetro	Valor
Tamanho da imagem	800×800 px
Número de épocas	200
Batch size	8
Taxa de aprendizado	10^{-3}
Early stopping	20 épocas

2.5 Métricas de performance

Para avaliar modelos de detecção, são utilizadas as métricas de Precisão, Recall e Acurácia, conforme as Equações 1, 2 e 3:

$$\text{Precisão} = \frac{VP}{VP + FP} \quad (1)$$

$$\text{Recall} = \frac{VP}{VP + FN} \quad (2)$$

$$\text{Acurácia} = \frac{VP + VN}{VP + VN + FP + FN} \quad (3)$$

calculadas a partir dos verdadeiros positivos (VP), verdadeiros negativos (VN), falsos positivos (FP) e falsos negativos (FN). A precisão estima a confiança nas previsões positivas, enquanto o recall mede a capacidade do modelo de encontrar todos os positivos.

3. RESULTADOS E DISCUSSÕES


3.1 Desempenho em treinamento e validação

Ao longo das 200 épocas o desempenho do modelo foi monitorado continuamente no conjunto de validação, e com o critério de *early stopping* configurado para encerrar o treinamento caso não fosse observada melhoria significativa nas métricas após 20 épocas consecutivas, a estabilidade foi atingida na época 69.

O processo de otimização foi conduzido com as funções de perda padrão do YOLOv10, compostas pela perda de localização, associada à precisão dos limites das caixas delimitadoras, e pela perda de classificação, associada ao erro entre as categorias previstas e as reais. A Figura 7 apresenta a evolução das duas perdas ao longo das épocas. A perda de localização caiu acentuadamente nas primeiras épocas, estabilizando-se em valores próximos de 0,3 no


treinamento e 2,5 na validação. A perda de classificação reduziu-se a valores próximos de 1 no conjunto de validação, demonstrando boa discriminação entre as classes.

Figura 7 – Evolução das perdas de (a) localização e (b) classificação ao longo das épocas.



Durante o treinamento, as métricas de Precisão e *Recall* no conjunto de validação atingiram valores finais de 97% e 96%, respectivamente, indicando que o modelo alcançou um equilíbrio satisfatório entre detecções corretas e abrangência das previsões. A Figura 8 apresenta a evolução dessas métricas ao longo das épocas.

Figura 8 – Evolução das métricas de Precisão e Recall no conjunto de validação.



A análise da matriz de confusão por classe permitiu calcular as métricas individuais apresentadas na Tabela 2. Observa-se que para a classe articulação foram registradas 56 classificações corretas e 5 incorretas, sendo 4 falsos negativos e 1 falso positivo, resultando em precisão de 98% e *recall* de 93%. A classe metacarpo apresentou 59 classificações corretas, com 1 falso positivo e 1 falso negativo, com precisão e *recall* de 98%. A classe carpo apresentou 60 predições corretas e 5 falsos positivos, atingindo precisão de 92% e *recall* de 100%. O índice global de acurácia foi de aproximadamente 0,93.

Tabela 2 – Resultados de validação para o modelo de segmentação.

Região	Precisão	Recall	Acurácia
Global	0,97	0,96	0,93
Articulação	0,98	0,93	-
Metacarpo	0,98	0,98	-
Carpo	0,92	1,00	-

Os pequenos erros observados na base de validação podem ser atribuídos à grande variabilidade introduzida intencionalmente pelas etapas de aumento de dados, com o objetivo de tornar o modelo mais robusto a diferentes padrões de posicionamento e iluminação. Essa diversidade expõe o modelo a cenários mais desafiadores do que aqueles presentes na base original, na qual a maioria das amostras apresenta disposições mais padronizadas. Espera-se, portanto, que o desempenho na base completa apresente resultados superiores aos observados em validação.

3.2 Aplicação na base completa

Após a etapa de validação, o modelo foi aplicado sobre o conjunto completo de 18.787 imagens. O tempo total de inferência usando apenas CPU foi de 2.188 segundos (≈ 36 minutos), correspondendo a uma média de aproximadamente 0,11 segundos por imagem, demonstrando a eficiência computacional do modelo YOLOv10s mesmo considerando o elevado número de detecções necessárias.

A análise das classificações sobre a base total mostrou que as três classes de interesse apresentaram taxas de Precisão e *Recall* superiores a 99,5%, indicando equilíbrio relevante entre as previsões corretas e o número de detecções realizadas para cada categoria. Dessa forma, a acurácia global manteve-se igualmente alta, em torno de 99,7%. A Figura 9 apresenta a matriz de confusão obtida sobre a base completa, evidenciando o elevado nível de acerto em todas as classes. Apenas 109 imagens não tiveram regiões detectadas automaticamente, sendo posteriormente recortadas de forma manual.

Figura 9 – Matriz de confusão obtida na aplicação do modelo sobre a base completa.

Classe Real	articulação	18713 (99.6%)			74 (0.4%)
	metacarpo -		18762 (99.7%)	24 (0.1%)	25 (0.1%)
	carpo -		14 (0.1%)	18755 (99.8%)	32 (0.2%)
	fundo -	17 (45.9%)	9 (24.3%)	11 (29.7%)	
		articulação	metacarpo	carpo	fundo
		Classe Predita			

3.3 Discussão

A maioria dos trabalhos existentes na literatura aplicada à idade óssea tende a não empregar técnicas de segmentação específicas ou a utilizar modelos baseados em arquiteturas tradicionais. Chu et al. (2018) utilizaram U-Net combinada com VGG16 para gerar máscaras no formato preciso da mão. Pan et al. (2020) também aplicaram U-Net acoplada a *Deep Active Learning* para segmentação da mão inteira. Zulkifley et al. (2021) optaram por DeepLab V3+ para isolar a mão do fundo, seguido de MobileNet V1 para reorientação. Em comum, essas abordagens segmentam a mão como um todo. Iglovikov et al. (2018) e Guo et al. (2022) avançaram ao explorar regiões mais específicas inspiradas nos centros de ossificação utilizados pelo método Tanner-Whitehouse, demonstrando que arquiteturas regionalizadas podem superar

análises holísticas. Ainda assim, em sua maior parte são empregados modelos genéricos de segmentação semântica.

Por outro lado, alguns trabalhos optam por não realizar segmentação, processando a imagem completa, como Wibisono et al. (2019) e Andleeb et al. (2025). Ainda que essa estratégia simplifique o pipeline, ela exige redes mais profundas e maior custo computacional para acomodar a alta resolução das radiografias e a variabilidade do fundo da imagem.

A utilização do YOLOv10 para a localização de regiões de interesse, conforme proposto neste trabalho, apresenta vantagens relevantes em relação às abordagens citadas. O modelo opera em estágio único, com um único *forward pass* pela rede, fornecendo simultaneamente coordenadas e classes das caixas delimitadoras. Esse comportamento, aliado ao baixo custo de anotação (apenas 204 imagens foram suficientes para alcançar acurácia global superior a 99% na base completa), torna a abordagem promissora para o avanço da automatização do fluxo de análise de radiografias da mão. Adicionalmente, o tempo médio de 0,11 segundos por imagem em CPU evidencia a viabilidade prática da solução, mesmo em ambientes sem aceleração por GPU. Ao restringir o processamento subsequente apenas às regiões clinicamente relevantes, e descartar áreas redundantes ou desprovidas de informação útil, é possível reduzir o custo computacional dos modelos de regressão da idade óssea aplicados em sequência, viabilizando arquiteturas mais leves operando sobre recortes de menor resolução.

4. CONCLUSÃO

Este trabalho apresentou uma metodologia para a segmentação automática de regiões anatômicas de interesse em radiografias da mão utilizando o modelo YOLOv10s, com foco em sua aplicação como etapa de pré-processamento em sistemas de avaliação automatizada da idade óssea. A combinação de uma estratégia criteriosa de seleção e anotação manual de 204 imagens, técnicas de aumento de dados e o uso de um detector de estágio único permitiu obter desempenho superior a 96% nas métricas de validação e acurácia global de 99,7% na base completa de 18.787 radiografias.

Em comparação com abordagens consolidadas na literatura que utilizam U-Net ou DeepLab para segmentação da mão, a metodologia proposta apresenta vantagens em termos de baixo custo de anotação, alta eficiência computacional ($\approx 0,11$ s por imagem em CPU) e capacidade de localizar simultaneamente múltiplas regiões clinicamente relevantes. Esses resultados validam o uso do YOLOv10 como ferramenta eficaz para a etapa de pré-processamento, viabilizando que análises de regressão posteriores operem sobre recortes de menor resolução e maior conteúdo discriminativo, reduzindo o custo computacional global do pipeline. Como trabalhos futuros, propõe-se a investigação de versões mais recentes da família YOLO, a expansão do conjunto anotado e a avaliação da metodologia em bases externas independentes, visando confirmar a robustez e generalização do modelo em diferentes contextos clínicos.

5. REFERÊNCIAS

- ANDLEEB, I. *et al.* Automatic evaluation of bone age using hand radiographs and pancorporal radiographs in adolescent idiopathic scoliosis. **Diagnostics**, v. 15, n. 4, p. 452, 2025.
- CHU, M.; LIU, B.; ZHOU, F.; BAI, X.; GUO, B. Bone age assessment based on two-stage deep neural networks. **Proceedings of the International Conference on Digital Image Computing: Techniques and Applications (DICTA)**. IEEE, 2018, p. 1-6.
- ESCOBAR, M.; GONZÁLEZ, C.; TORRES, F.; DAZA, L.; TRIANA, G.; ARBELÁEZ, P. Hand pose estimation for pediatric bone age assessment. **Proceedings of the Medical Image Computing and Computer Assisted Intervention (MICCAI)**. Springer, 2019, p. 531-539.

GREULICH, W. W.; PYLE, S. I. **Radiographic Atlas of Skeletal Development of the Hand and Wrist**. 2. ed. Stanford: Stanford University Press, 1959.

GUO, L.; WANG, J.; TENG, J.; CHEN, Y. Bone age assessment based on deep convolutional features and fast extreme learning machine algorithm. **Frontiers in Energy Research**, v. 9, p. 813650, 2022.

IGLOVIKOV, V. I.; RAKHLIN, A.; KALININ, A. A.; SHVETS, A. A. Paediatric bone age assessment using deep convolutional neural networks. **Proceedings of DLMIA/ML-CDS, MICCAI 2018**. Springer, 2018, p. 300-308.

LITJENS, G. *et al.* A survey on deep learning in medical image analysis. **Medical Image Analysis**, v. 42, p. 60-88, 2017.

MELMED, S.; POLONSKY, K. S.; LARSEN, P. R.; KRONENBERG, H. M. **Williams Textbook of Endocrinology**. 13. ed. Philadelphia: Elsevier Health Sciences, 2015.

PAN, X.; ZHAO, Y.; CHEN, H.; WEI, D.; ZHAO, C.; WEI, Z. Fully automated bone age assessment on large-scale hand X-ray dataset. **International Journal of Biomedical Imaging**, v. 2020, p. 1-12, 2020.

RAIAAN, M. A. K. *et al.* A systematic review of hyperparameter optimization techniques in convolutional neural networks. **Decision Analytics Journal**, v. 11, p. 100470, 2024.

REDMON, J.; DIVVALA, S.; GIRSHICK, R.; FARHADI, A. You only look once: unified, real-time object detection. **Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)**, 2016, p. 779-788.

RADIOLOGICAL SOCIETY OF NORTH AMERICA. **RSNA Pediatric Bone Age Challenge 2017**. 2017. Disponível em: <https://www.rsna.org/education/ai-resources-and-training/ai-image-challenge/rsna-pediatric-bone-age-challenge-2017>. Acesso em: 26 mai. 2026.

SATOH, M. Bone age: assessment methods and clinical applications. **Clinical Pediatric Endocrinology**, v. 24, n. 4, p. 143-152, 2015.

SHOME, S. K.; VADALI, S. R. K. Enhancement of diabetic retinopathy imagery using contrast limited adaptive histogram equalization. **International Journal of Computer Science and Information Technologies**, v. 2, n. 6, p. 2694-2699, 2011.

TANNER, J. M.; WHITEHOUSE, R. H.; MARSHALL, W. A.; CARTER, B. S. Prediction of adult height from height, bone age, and occurrence of menarche, at ages 4 to 16 with allowance for midparent height. **Archives of Disease in Childhood**, v. 50, n. 1, p. 14-26, 1975.

THODBERG, H. H.; KREIBORG, S.; JUUL, A.; PEDERSEN, K. D. The BoneXpert method for automated determination of skeletal maturity. **IEEE Transactions on Medical Imaging**, v. 28, n. 1, p. 52-66, 2008.

WANG, Z. *et al.* A comprehensive survey on data augmentation. **IEEE Transactions on Knowledge & Data Engineering**, v. 38, n. 01, p. 47-66, 2026.

WIBISONO, A. *et al.* Deep learning and classic machine learning approach for automatic bone age assessment. **Proceedings of the 4th Asia-Pacific Conference on Intelligent Robot Systems (ACIRS)**. IEEE, 2019, p. 235-240.

ZULKIFLEY, M. A. *et al.* Intelligent bone age assessment: an automated system to detect a bone growth problem using convolutional neural networks with attention mechanism. **Diagnostics**, v. 11, n. 5, p. 765, 2021.

NOTAS

CONTRIBUIÇÃO DE AUTORIA

Concepção e elaboração do manuscrito: B. B. d. Oliveira, M. B. P. Carneiro

Coleta de dados: B. B. d. Oliveira

Análise de dados: B. B. d. Oliveira

Discussão dos resultados: B. B. d. Oliveira, M. B. P. Carneiro

Revisão e aprovação: M. B. P. Carneiro

PREPRINTS

O manuscrito não é um preprint.

AGRADECIMENTOS

Os autores agradecem ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Uberlândia pelo suporte acadêmico e institucional fornecido. Estendem ainda seus agradecimentos ao comitê da Conferência de Estudos em Engenharia Elétrica (CEEL) pela oportunidade de divulgação deste trabalho e pela promoção de um ambiente de intercâmbio científico e tecnológico. Por fim, agradecem a todos que contribuíram direta ou indiretamente para a realização desta pesquisa.

FINANCIAMENTO

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) – Código de Financiamento 001. Número do projeto 88887.918718/2023-00.

CONFLITO DE INTERESSES

Os autores declaram não haver conflito de interesses.

DISPONIBILIDADE DE DADOS DE PESQUISA E OUTROS MATERIAIS

Os dados foram publicados no próprio artigo. Todo o conjunto de dados que dá suporte aos resultados deste estudo está incluído no corpo do artigo.

ANUÊNCIA DE AVALIAÇÃO ABERTA

Não se aplica.



O conteúdo deste trabalho pode ser usado sob os termos da licença Creative Commons Attribution 4.0. Qualquer outra distribuição deste trabalho deve manter a atribuição ao(s) autor(es) e o título do trabalho, citação da revista e DOI.