

# Diagnóstico Automático de Fraturas do Escafoide em Radiografias do Punho Usando Arquiteturas de Redes Neurais Convolucionais

Luiz F. A. Guerra<sup>1</sup>, Carine de O. Vieira<sup>1</sup>, Augusto C. R. Xavier<sup>1</sup>,  
Giovanni L. F. da Silva<sup>1</sup>, João O. B. Diniz<sup>2</sup>

<sup>1</sup>Centro Universitário Unidade de Ensino Superior Dom Bosco - UNDB  
Caixa Postal 65075-441 - São Luís - MA - Brasil

<sup>2</sup>Instituto Federal do Maranhão - IFMA  
Caixa Postal 65940-000 - Grajaú - MA - Brasil

l.felipeguerra@hotmail.com, carinevieir@yahoo.com.br  
augustocrx.eng@gmail.com, giovanni.silva@undb.edu.br  
joao.bandeira@ifma.edu.br

**Abstract.** *Scaphoid fractures represent a persistent challenge in wrist radiography, especially in non-displaced cases and in the early stages of trauma. Therefore, this work proposes a method based on Convolutional Neural Networks for the automatic detection and diagnosis of scaphoid fractures in wrist radiographs. The proposed method employs Faster R-CNN with ResNet-50 backbone for scaphoid detection and InceptionResNetV2 for fracture classification. Preliminary results demonstrated good performance with an IoU of 93.1% in scaphoid detection and 98.22% accuracy in fracture diagnosis. The findings indicate strong potential for this approach to support the radiographic diagnosis of scaphoid fractures.*

**Resumo.** *As fraturas do escafoide representam um desafio persistente na radiografia do punho, especialmente em casos não deslocados e em estágios iniciais do trauma. Diante disso, este trabalho propõe um método baseado em Redes Neurais Convolucionais para detecção automática e diagnóstico de fraturas em radiografias do punho. O método proposto emprega Faster R-CNN com backbone ResNet-50 para detecção do escafoide e InceptionResNetV2 para classificação. Resultados preliminares demonstraram bom desempenho, com IoU de 93,1% na detecção e acurácia de 98,22% no diagnóstico. Os achados indicam potencial da abordagem para apoio ao diagnóstico radiográfico.*

## 1. Introdução

As fraturas do escafoide representam um desafio clínico e radiológico recorrente. Apesar de corresponderem à maioria das fraturas dos ossos do carpo, muitas não são identificadas na avaliação inicial por radiografia convencional, especialmente quando não apresentam deslocamento [Alshamrani 2023]. Essa dificuldade está relacionada à anatomia complexa do escafoide, à sua vascularização limitada e à sobreposição de estruturas nas radiografias [Żyluk 2023].

Mesmo com protocolos clínicos adequados, estima-se que entre 30% e 40% das fraturas possam não ser detectadas na radiografia inicial [Mallee et al. 2016]. O

atraso no diagnóstico pode resultar em complicações como pseudoartrose e necrose avascular [Mallee et al. 2016]. Dessa forma, torna-se necessária a utilização de ferramentas que auxiliem na identificação precoce dessas lesões [Kraus et al. 2024].

A Inteligência Artificial (IA), especialmente por meio de técnicas de Redes Neurais Convolucionais (CNN), tem se destacado na análise de imagens médicas. Esses modelos são capazes de identificar padrões sutis em radiografias e podem alcançar desempenho comparável ao de especialistas humanos [Sharma 2023]. Além disso, contribuem para maior padronização das decisões diagnósticas [Oeding et al. 2024].

Diante desse contexto, o desenvolvimento de métodos automatizados para detecção e diagnóstico de fraturas do escafoide torna-se relevante. Estudos recentes indicam que modelos de aprendizagem profunda podem alcançar elevada sensibilidade e especificidade na análise de radiografias [Kraus et al. 2024]. Assim, este trabalho propõe um método baseado em Redes Neurais Convolucionais para detecção automática do escafoide e diagnóstico de fraturas em radiografias do punho. Desta forma, o trabalho apresenta as seguintes contribuições:

- Proposição de uma abordagem automatizada em dois estágios para detecção e diagnóstico de fraturas do escafoide em radiografias do punho;
- Validação da abordagem em bases públicas de imagens radiográficas, demonstrando o potencial do método como ferramenta de apoio ao diagnóstico radiológico

## **2. Trabalhos Relacionados**

Diversos estudos aplicam aprendizado profundo na detecção de fraturas do escafoide em radiografias. [Hendrix et al. 2021] utilizaram um modelo com duas CNNs para segmentação e detecção, alcançando Dice de 97,4% e AUC de 0,87. De forma semelhante, [Yang et al. 2022] propuseram uma abordagem em dois estágios com Faster R-CNN e ResNet, obtendo AUC de 0,92.

Abordagens mais recentes buscam maior robustez diagnóstica. [Yang et al. 2024] exploraram fusão multi-view, atingindo 89,94% de acurácia, enquanto [Bützow et al. 2025] apresentaram segmentação hierárquica com detecção de fraturas ocultas, alcançando AUC de 0,92.

Apesar dos avanços, persistem limitações como uso de bases de dados restritas, pouca clareza na separação entre etapas de processamento, o que pode comprometer a generalização e a escalabilidade dos métodos. Diante disso, o método proposto utiliza duas bases de imagens diferentes, demonstrando robustez.

## **3. Materiais e Método**

O método proposto está estruturado em quatro etapas principais, conforme ilustrado na Figura 1. Inicialmente, realiza-se o pré-processamento das radiografias. Em seguida, é feita a detecção automática da região do escafoide utilizando Faster R-CNN. Na terceira etapa, ocorre a extração das regiões de interesse (ROIs) a partir das detecções obtidas. Por fim, essas regiões são submetidas a um modelo de classificação baseado na arquitetura InceptionResNetV2 para identificar a presença de fraturas. Todas as etapas são descritas detalhadamente a seguir.

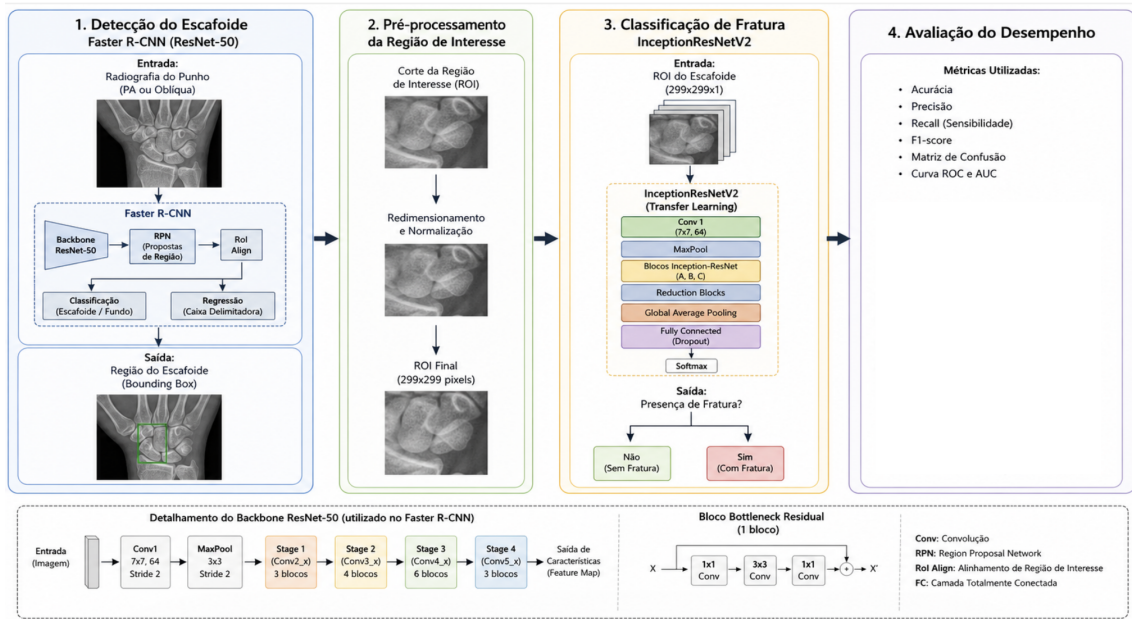


Figura 1. Fluxo das etapas do método proposto.

### 3.1. Materiais

Para a validação do método proposto, foram utilizadas duas bases de dados públicas, cada uma associada a uma etapa do pipeline. A detecção do escafoide foi realizada com o *Scaphoid-Scanner Dataset* [Scaphoids 2023], originalmente com 2.400 radiografias, reduzido para 1.331 imagens após remoção de incidências laterais devido à baixa visibilidade da estrutura. Já a etapa de diagnóstico de fratura utilizou a base *Bone Fracture Multi-Region X-ray Data* [Rodrigo et al. 2024], composta por 10.581 imagens, distribuídas entre casos com e sem fratura, com diferentes resoluções.

### 3.2. Detecção do escafoide

A detecção do escafoide em radiografias do punho foi realizada utilizando o modelo Faster R-CNN, tendo como *backbone* a arquitetura ResNet-50 [Gomaa et al. 2022]. Uma das principais vantagens do Faster R-CNN é a incorporação da *Region Proposal Network* (RPN), responsável por gerar automaticamente regiões candidatas de interesse. Esse mecanismo permite integrar a geração de propostas ao próprio processo de detecção.

### 3.3. Pré-processamento das imagens

Após a detecção do escafoide, foi realizada uma etapa de pré-processamento com o objetivo de otimizar o desempenho do modelo de diagnóstico. Nessa etapa, as regiões de interesse detectadas foram redimensionadas para padronizar suas resoluções, uma vez que apresentam tamanhos distintos. Além disso, o filtro de mediana foi aplicado para reduzir ruídos impulsivos frequentemente presentes em radiografias digitalizadas, preservando bordas estruturais importantes para a análise óssea.

### 3.4. Diagnóstico de fratura

O diagnóstico da presença ou ausência de fratura no escafoide é realizado por uma CNN baseada na arquitetura InceptionResNetV2 [Yang et al. 2022]. Essa arquitetura

foi escolhida devido à sua capacidade de combinar módulos *Inception*, responsáveis por capturar padrões em diferentes escalas, com conexões residuais que facilitam o treinamento da rede. Essa combinação permite extrair características mais discriminativas e reduzir problemas como o desaparecimento do gradiente, contribuindo para maior estabilidade e desempenho do modelo.


## 4. Resultados e Discussão

Nesta seção são apresentados os resultados preliminares obtidos com o método proposto para a detecção automática e o diagnóstico de fraturas do escafoide a partir de imagens radiográficas do punho.

### 4.1. Desempenho na detecção do escafoide

O desempenho do modelo de detecção do escafoide foi avaliado utilizando a divisão original da base [Scaphoids 2023], alcançando IoU médio de 93,1% no conjunto de teste. A Figura 2 ilustra casos de acerto (IoU > 90%) e falha (IoU < 80%) em relação à anotação do especialista. Mesmo nos casos com menor IoU, observa-se que o modelo identifica corretamente a região do escafoide, evidenciando sua capacidade de localização precisa em radiografias do punho.

**Figura 2. Resultado na etapa de detecção do escafoide. Casos de sucesso (a) e casos de falha (b).**



A Faster R-CNN para detecção do escafoide foi treinada com otimizador SGD, perda baseada na RPN, 10 épocas, taxa de aprendizado de 0,005, *momentum* de 0,9 e lote de 4 imagens. O modelo apresentou maior eficiência computacional em relação a abordagens com geração externa de regiões [Roh and Lee 2017, Sharma 2023, Kraus et al. 2024], mantendo alta precisão na localização, característica essencial em aplicações médicas com elevada exigência espacial.

### 4.2. Desempenho no diagnóstico de fratura

A Tabela 1 apresenta a divisão dos conjuntos de treinamento, validação e teste utilizados na etapa de diagnóstico de fraturas. O modelo obteve uma acurácia de 98,02% no conjunto de teste, indicando que a maioria das imagens foi corretamente classificada. A precisão alcançada foi de 97,76%, evidenciando a capacidade do modelo em reduzir a ocorrência de falsos positivos, enquanto o *recall*, de 98,50%, demonstra sua eficiência em identificar corretamente os casos de fratura.

Os hiperparâmetros utilizados para o treinamento da InceptionResNetV2 foram o otimizador Adadelta, 100 épocas de treinamento com uso de *EarlyStopping*, taxa de

**Tabela 1. Resultados do modelo no diagnóstico de fratura do escafoide.**

<b>Conjunto</b>	<b>Quantitativo</b>	<b>Acurácia</b>	<b>Precisão</b>	<b>Recall</b>
Treinamento	9.246	-	-	-
Validação	829	-	-	-
Teste	506	98,02%	97,76%	98,50%

aprendizado inicial de 0,05 com *momentum* de 0,8 e valor mínimo de 0,0001, além de um lote de 50 imagens.

O pipeline apresentou tempo médio de processamento de 62 ms por exame em GPU NVIDIA L4, indicando viabilidade para aplicações clínicas em tempo real. Além disso, sistemas automatizados de detecção de fraturas podem apoiar a decisão médica em contextos de urgência, contribuindo para maior acurácia e concordância diagnóstica, especialmente entre médicos não especialistas, e auxiliando na redução de complicações [Lee et al. 2023].

## 5. Conclusão

O trabalho propõe um método baseado em CNNs para detecção do escafoide e diagnóstico de fraturas em radiografias do punho. A abordagem em dois estágios, com Faster R-CNN e InceptionResNetV2, apresentou alto desempenho, alcançando IoU de 93,1% e acurácia de 98,22%. Os resultados evidenciam o potencial da IA como suporte ao diagnóstico radiológico, contribuindo para maior precisão e detecção precoce.

Como trabalhos futuros, pretende-se otimizar hiperparâmetros, aplicar validação cruzada e incorporar métodos de explicabilidade, como Grad-CAM, visando maior robustez, interpretabilidade e aplicabilidade clínica.

## Agradecimentos

Este trabalho foi desenvolvido com o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES), por meio do Código de Financiamento 001, da Fundação de Amparo à Pesquisa e ao Desenvolvimento Científico e Tecnológico do Maranhão (FAPEMA) e do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq).

## Referências

- Alshamrani, H. A. (2023). Accuracy of the radiological protocols in detecting scaphoid fractures, a retrospective study. *Signa Vitae*, 19(4).
- Bützow, A., Anttila, T., Haapamäki, V., and Ryhänen, J. (2025). A novel segmentation-based deep learning model for enhanced scaphoid fracture detection. *European Journal of Radiology*, page 112309.
- Gomaa, A., Minematsu, T., Abdelwahab, M. M., Abo-Zahhad, M., and Taniguchi, R.-i. (2022). Faster cnn-based vehicle detection and counting strategy for fixed camera scenes. *Multimedia Tools and Applications*, 81(18):25443–25471.
- Hendrix, N., Scholten, E., Vernhout, B., Bruijnen, S., Maresch, B., de Jong, M., Diepstraten, S., Bollen, S., Schalekamp, S., de Rooij, M., et al. (2021).

- Development and validation of a convolutional neural network for automated detection of scaphoid fractures on conventional radiographs. *Radiology: Artificial Intelligence*, 3(4):e200260.
- Kraus, M., Anteby, R., Konen, E., Eshed, I., and Klang, E. (2024). Artificial intelligence for x-ray scaphoid fracture detection: a systematic review and diagnostic test accuracy meta-analysis. *European radiology*, 34(7):4341–4351.
- Lee, K.-C., Choi, I. C., Kang, C. H., Ahn, K.-S., Yoon, H., Lee, J.-J., Kim, B. H., and Shim, E. (2023). Clinical validation of an artificial intelligence model for detecting distal radius, ulnar styloid, and scaphoid fractures on conventional wrist radiographs. *Diagnostics*, 13(9):1657.
- Mallee, W. H., Mellema, J. J., Guitton, T. G., Goslings, J. C., Ring, D., Doornberg, J. N., and of Variation Group, S. (2016). 6-week radiographs unsuitable for diagnosis of suspected scaphoid fractures. *Archives of orthopaedic and trauma surgery*, 136(6):771–778.
- Oeding, J. F., Kunze, K. N., Messer, C. J., Pareek, A., Fufa, D. T., Pulos, N., and Rhee, P. C. (2024). Diagnostic performance of artificial intelligence for detection of scaphoid and distal radius fractures: a systematic review. *The Journal of Hand Surgery*, 49(5):411–422.
- Rodrigo, M. S. et al. (2024). Bone fracture multi-region x-ray data. Kaggle dataset. Accessed: 28 Sep 2025.
- Roh, M.-C. and Lee, J.-y. (2017). Refining faster-rcnn for accurate object detection. In *2017 fifteenth IAPR international conference on machine vision applications (MVA)*, pages 514–517. IEEE.
- Scaphoids (2023). Scaphoid-scanner dataset. <https://universe.roboflow.com/scaphoids/scaphoid-scanner>. visited on 2025-10-29.
- Sharma, S. (2023). Artificial intelligence for fracture diagnosis in orthopedic x-rays: current developments and future potential. *SICOT-J*, 9:21.
- Yang, T.-H., Horng, M.-H., Li, R.-S., and Sun, Y.-N. (2022). Scaphoid fracture detection by using convolutional neural network. *Diagnostics*, 12(4):895.
- Yang, T.-H., Sun, Y.-N., Li, R.-S., and Horng, M.-H. (2024). The detection and classification of scaphoid fractures in radiograph by using a convolutional neural network. *Diagnostics*, 14(21):2425.
- Żyluk, A. (2023). Diagnostics and management of acute scaphoid fractures: an update. *Pomeranian Journal of Life Sciences*, 69(3).