

Detecção automática de pedra no rim em tomografia computadorizada utilizando CNN

Gabriel Nunes Missima¹, Murillo Freitas Bouzon²,
Oscar Eduardo Hidetoshi Fugita³, Paulo Sergio Silva Rodrigues⁴
^{1, 2, 4} Centro Universitário FEI, São Bernardo do Campo, Brasil
³ Hospital Universitário da USP, São Paulo, Brasil
unifgmissima@fei.edu.br¹ mfbouzon@fei.edu.br²

Resumo: O diagnóstico automático de cálculos renais a partir de imagens de tomografia computadorizada é uma ferramenta estratégica para acelerar o processo de cuidado ao paciente. Embora abordagens de aprendizado profundo tenham mostrado resultados promissores, muitas delas são complexas e exigem alto poder computacional. Este trabalho propõe um método de baixa complexidade para detectar cálculos renais em imagens e analisa os mapas de ativação gerados para entender sua classificação.

I. INTRODUÇÃO

As pedras nos rins, ou cálculos renais, são formações endurecidas que se desenvolvem no interior dos rins, ureter, bexiga ou uretra, como visto na Fig. 1. Essas massas podem variar em tamanho e composição, mas geralmente são compostas por cristais de sais minerais presentes na urina que podem levar a dor intensa e danos permanentes aos órgãos internos do paciente [1]. A rápida detecção e diagnóstico precoce desses cálculos são essenciais para prevenir complicações e iniciar uma estratégia de tratamento eficiente. A utilização de tomografias computadorizadas (TC) é o principal exame de coleta de imagens para diagnóstico de cálculos [2].




Fig. 1: Ilustração de cálculos no sistema urinário.

Recentemente, técnicas de aprendizado profundo têm sido aplicadas com sucesso na detecção automática de cálculos renais em imagens geradas por tais exames [3]. Modelos de aprendizado são treinados para diferenciar entre imagens de pacientes saudáveis e pacientes com cálculos renais. Alguns estudos alcançaram alta precisão, mas essas técnicas complexas exigem alto custo computacional e tempo de treinamento. Outro ponto negativo é a falta de um método de visualização de quais áreas o modelo levou em consideração para realizar o diagnóstico, pois essa visualização, além de aumentar a compreensão da funcionalidade do modelo, pode servir para auxiliar o

médico em identificar as regiões de interesse em que o paciente está sendo afetado pelos cálculos.

As contribuições deste trabalho incluem: um modelo baseado em rede neural convolucional (CNN) [4] para o diagnóstico de pedras no rim; a expansão de uma base de dados com imagens TC para detecção de pedras no rim; análise dos mapas de ativação do modelo treinado para compreensão das regiões de interesse para o diagnóstico de cálculos.

II. METODOLOGIA

O método recebe como dados de entrada um conjunto de imagens de TC da região frontal do abdômen do paciente (coronal). As imagens foram inicialmente pré-processadas, sendo feito um redimensionamento e uma normalização do seu espaço de cor. Então, a rede neural baseada em CNN é treinada com as imagens pré-processadas para a classificação, sendo definidas em duas classes: imagens com cálculo ou normais. Após o treinamento, a última camada intermediária do modelo foi selecionada para gerar e analisar os mapas de ativação do modelo treinado. Esse esquema é apresentado na Fig. 2 a seguir:

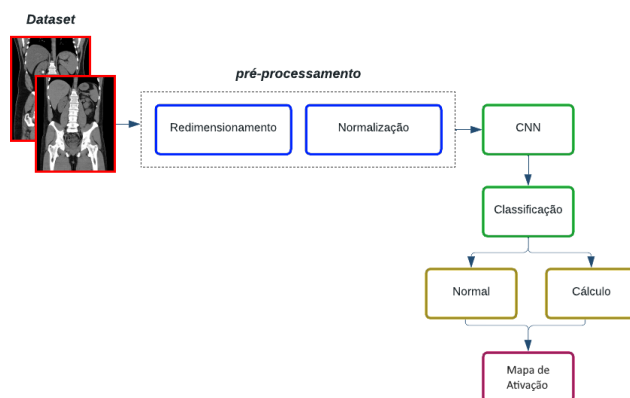


Fig. 2: Fluxograma da metodologia proposta.

A. Base de Dados

Foram utilizadas no total 3383 imagens de TC (1304 com cálculos e 2079 sem cálculos) para a realização deste trabalho. As imagens em questão foram divididas em 80% para treino, 10% para validação e 10% para teste. As bases de dados utilizadas foram:

- Base apresentada no trabalho de Yildirim et al. (2021) [5] (disponível publicamente em <<https://github.c>

om/yildirimozal/Kidney_stone_detection>) - 1799 imagens, sendo 790 que possuem cálculos e 1009 considerados normais.

- Base coletada pelo PACS (disponível publicamente em <<https://kaggle.com/datasets/nazmul0087/c-t-kidney-dataset-normal-cyst-tumor-and-stone>>), selecionadas TC coronais sem tumores, com e sem cálculos - 1584 imagens, sendo 514 que possuem cálculos e 1070 considerados normais.

B. Rede Neural Convolutacional

Para o problema proposto, a CNN utilizada, representada na Fig. 3, recebeu o conjunto de imagens em tons de cinza da Base de Dados. As imagens que estão na dimensão 224×224 e normalizadas, com os seus valores de intensidade variando entre 0 e 1, conforme descrito na Metodologia. Para investigar o desempenho das camadas convolucionais na classificação das amostras foram feitos 10 testes separando as imagens entre treino, teste e validação de maneira aleatória. Foi utilizado o otimizador Adam, 150 épocas e um *batch* de tamanho 32. Por fim, a última camada convolutacional do modelo, chamada de camada intermediária, foi selecionada para gerar o mapa de ativação.

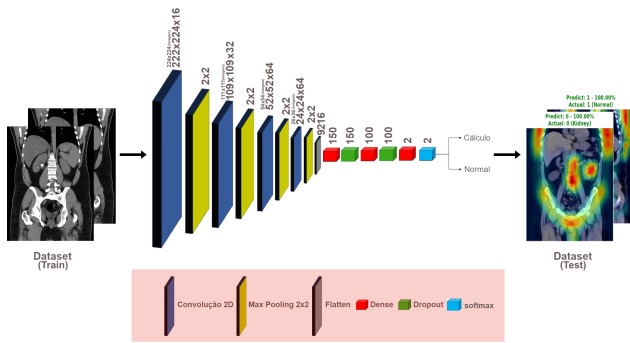


Fig. 3: Arquitetura de CNN (Conv4) utilizada.

III. CONCLUSÕES

Os resultados do modelo treinado são apresentados na Tabela I: A acurácia variou entre 96-98%, indicando uma baixa taxa de erro geral. Foi obtida uma precisão no diagnóstico com cerca de 94% das imagens normais e 99% das imagens com cálculos renais.

TABLE I: Média de 10 resultados obtidos

	Precision	Recall	F1-Score	Support
<i>KD</i>	99% ± 1%	89% ± 2%	96% ± 2%	130
<i>Normal</i>	94% ± 2%	99% ± 1%	98% ± 2%	207
<i>Accuracy</i>			97% ± 1%	337
<i>Macro AVG</i>	97% ± 1%	95% ± 2%	97% ± 1%	337
<i>Weighted AVG</i>	96% ± 2%	96% ± 2%	97% ± 1%	337

Além disto, os mapas de ativação foram gerados nas imagens testadas para análise da classificação do modelo. Observando a Fig.4, nota-se que o modelo está ativando corretamente nas regiões onde o cálculo está localizado, influenciando a classificação positiva da rede. Na Fig.5, o modelo não ativou nas regiões correspondentes ao rim, indicando que nestes casos onde não há cálculo presente, desconsiderando então essas regiões na sua classificação.




Fig. 4: Apresentação de mapas de ativação com cálculos.




Fig. 5: Apresentação de mapas de ativação sem cálculos.

Neste trabalho foi proposto um método para detecção automática de cálculos renais em TC utilizando uma CNN de baixo custo com uma base de dados expandida e a análise dos mapas de ativação gerados pelo mesmo.

Para etapas futuras, deseja-se aumentar a base de dados com as TC exclusivas fornecidas pelo Hospital Universitário da USP que ainda precisam ser convertidas e organizadas, além de testar novas perspectivas de TC (axial e sagital). Também, pretende-se testar outras arquiteturas CNN para comparação de desempenho e eficiência.

IV. REFERÊNCIAS

- [1] Johann P Ingimarsson et al. “Diagnosis and management of nephrolithiasis”. In: *Surgical Clinics* 96.3 (2016), pp. 517–532.
- [2] Godfrey N Hounsfield. “Computerized transverse axial scanning (tomography): Part 1. Description of system”. In: *The British journal of radiology* 46.552 (1973), pp. 1016–1022.
- [3] BM Zeeshan Hameed et al. “Artificial intelligence and its impact on urological diseases and management: A comprehensive review of the literature”. In: *Journal of Clinical Medicine* 10.9 (2021), p. 1864.
- [4] Yann LeCun et al. “Gradient-Based Learning Applied to Document Recognition”. In: *Proceedings of the IEEE* 86 (1998), pp. 2278–2324.
- [5] Kadir Yildirim et al. “Deep learning model for automated kidney stone detection using coronal CT images”. In: *Computers in biology and medicine* 135 (2021), p. 104569.

AGRADECIMENTOS

Em especial ao Centro Universitário FEI pelo espaço e oportunidade, Hospital Universitário da USP pela disponibilização das imagens de Tomografia Computadorizada, além das instituições FAPESP, CAPES e CNPq pelo apoio dado a este trabalho.

¹ Aluno de IC do Centro Universitário FEI. Projeto com vigência de 02/2024 a 01/2025.

² Co-Orientador de IC do Centro Universitário FEI.

³ Professor do Hospital Universitário da USP.

⁴ Orientador de IC e Professor do Centro Universitário FEI.