

Aprendizado Profundo para Detecção de Cálculos Renais em Imagens de Tomografia Computadorizada

Deep Learning for Kidney Stones Detection in CT Images

Camila Catiely de Sá
Almondes
Programa de Pós Graduação
em Engenharia Elétrica,
Universidade Federal do Piauí
- Teresina, Brasil
cctiely97@gmail.com

Vitoria Karolina Ferreira
de Sousa
Graduação em Sistemas de
Informação,
Universidade Federal do Piauí
- Picos, Brasil
vivikarolfe@ufpi.edu.br

Flavio H. D. Araujo
Programa de Pós Graduação
em Engenharia Elétrica,
Departamento de Sistemas de
Informação,
Universidade Federal do
Piauí, Brasil
flavio86@ufpi.edu.br

ABSTRACT

Calcification is a commonly observed disease and is of people prepared by stauorologists using computed (CT) imaging, and the number of computerized diseases has increased exponentially in industrialized countries. This abnormality is when the urine has more calcium than normal substances such as and oxalate. The changing habits of today's society form an early detection that late in the kidneys, an advanced detection for an early stage is extremely crucial, an advanced detection for an advanced stage is crucial to help dissolve and eliminate the stone. This work presents an evaluation of the pre-processing methods: Median Filter and CLAHE, with pre-trained descriptors *DenseNet201*, *VGG16*, *RESNET50* and *Xception*, and the *Multi-layer Perceptron* (MLP) and *Random Forest* (RF), for detection of calcifications on CT images of the urinary tract. For the evaluation of the proposed method, 10 exams were used, totaling 2,790 images with calcification and 2,312 images without calcifications. The evaluated scenario (With Calc x Without Calcification) and the best results were obtained with the X descriptor of 0.94.86.

Keywords

Computed tomography; Kidney stone; Computer vision; Feature Extraction; Classification

RESUMO

A calcificação renal é uma doença comumente observada e geralmente é detectada por urologistas utilizando imagens de tomografia computadorizada (TC), e o número de pessoas com esta patologia tem aumentado exponencialmente nos países industrializados. Esta anomalia é formada quando a urina apresenta quantidades maiores que o normal de subs-

tâncias, como cálcio e oxalato. A mudança de hábitos da sociedade atual forma um agravante a detecção tardia de cálculos renais, sendo que, uma detecção em estágio inicial é extremamente crucial para um melhor prognóstico, possibilitando através de remédios ajudar a dissolver e eliminar a pedra. Este trabalho apresenta a avaliação dos métodos de pré-processamento: Filtro da Mediana e o CLAHE, com os descritores pré-treinados *DenseNet201*, *VGG16*, *RESNET50* e *Xception*, e os classificadores *Multi-layer Perceptron* (MLP) e *Random Forest* (RF), para a detecção de calcificações em imagens de TC do trato urinário. Para a avaliação do método proposto foram utilizados 10 exames, que totalizaram 2.790 imagens com calcificação e 2.312 imagens sem calcificações. O cenário avaliado foram (Com Calcificação x Sem Calcificação) e os melhores resultados foram alcançados com o descritor Xception e o classificador MLP nas imagens com o Filtro da Mediana com a Acurácia de 0,94 e AUC de 0,86.

Palavras-Chave

Tomografia computadorizada; Cálculo renal; Visão Computacional; Extração de Características; Classificação

CCS Concepts

• **AUC** → **Area under the receiver operating characteristic curve**; • **CNN** → **Convolutional neural network**; • **DICOM** → **Digital Imaging and Communications in Medicine**; • **DL** → **Deep Learning**; • **TC** → **Computed Tomography**;

1. INTRODUÇÃO

O cálculo renal, é uma doença comumente conhecida como pedra nos rins, é um quadro agudo que se instala em maioria nos homens do que nas mulheres provocando dores intensas[38]. Ela possui um elevado impacto social e alto custo, tendo em vista que afeta de 5 a 15% das pessoas em algum momento da vida, apresentando elevadas taxas de recorrência. Esta patologia é identificada como uma massa sólida formada por pequenos cristais, que podem ser encontrados tanto nos rins quanto em qualquer outro órgão da região renal[2]. Os países industrializados e de clima tropical têm uma maior incidência de cálculos urinários quando comparados aos países em desenvolvimento, isto ocorre devido as diferenças entre o tipo de alimentação e da perda de água

Permission to make digital or hard copies of all or part of this work for personal or classroom use is granted without fee provided that copies are not made or distributed for profit or commercial advantage and that copies bear this notice and the full citation on the first page. To copy otherwise, or republish, to post on servers or to redistribute to lists, requires prior specific permission and/or a fee.

através do suor, quando as pessoas ingerem menos água do que transpiram[20].

Sabe-se que 1 em cada 100 pessoas irá desenvolver pedras renais ao longo da vida, sendo que, em cerca de 80% dos casos, as pedras serão eliminadas espontaneamente [34]. Os 20% restantes irão necessitar de tratamento, com possibilidade de remoção através de cirurgia. Se não for devidamente tratada, é uma patologia que, em metade dos doentes, poderá reaparecer num prazo de 10 anos. Globalmente, sua presença é estimada em 2% a 3% da população geral. Os estudos apontam para o fato de que, aos 70 anos de idade, cerca de 12% das pessoas apresentaram, pelo menos, um episódio de cálculos renais [36].

A doença apresenta sintomas que normalmente surgem de forma repentina, quando a calcificação se desloca pelas vias urinárias, gerando uma dor muito forte nas costas que deve ser tratada o mais rápido possível em um hospital ou pronto-socorro[16]. Cálculos localizados dentro do rim habitualmente são assintomáticos, estes somente incomodarão quando se movimentarem para sair do rim e se encaminharem até a bexiga. Nesta situação pode se manifestar dores agudas e outros sintomas associados, como por exemplo: Dor lombar variável excessiva e cólica, que pode se irradiar para o abdômen inferior e região genital (até vulva ou testículo), náuseas e vômitos, ardência para urinar, febre, calafrios e suor excessivo[32]. Os cálculos que não apresentam sintomas são identificados em exames de rotina, por um especialista (Urologista), mas é importante ressaltar que mesmo que esses cristais não se manifestem é preciso realizar exames para se avaliar e definir se tem alguma complicação concomitante (infecção de urina, comprometimento da função renal etc), e o tamanho do cálculo para definir o melhor tratamento para o paciente. No início da crise, indicando a presença das "pedras dos rins", as dores são acentuadas e se somente resolvem-se com medicamentos via intravenosa[13]. Exames de imagem são essenciais para a identificação das calcificações. Ultrassonografia e radiografia de abdômen são bons exames de triagem e acompanhamento, mas o exame padrão ouro para diagnóstico e indicação do tratamento é a tomografia computadorizada de abdômen [17]. A tomografia computadorizada (TC) apresenta a sensibilidade sem contraste para detecção de urolitíase superior a 95% [15]. E o reconhecimento da doença precisa ser de forma rápida, pois a falha em reconhecer e tratar prontamente a existência do cálculo pode levar ao aumento da mortalidade e colocar os pacientes em situação de emergência. Dessa forma, se faz necessário o desenvolvimento de soluções para análise de imagens de TC do Abdômen para uma investigação prematuramente [29].

A localização precisa da pedra em radiografia simples geralmente era indeterminada, apenas é possível visualizar por tomografia computadorizada axial. Fora do período de crise pode-se realizar uma avaliação metabólica que incluem exames de sangue e urina para tentar se determinar o fator formador dos cálculos urinários e então tentar prevenir a formação de novos cálculos [41]. Na maioria das vezes o cálculo renal é descoberto pelo médico de plantão em Unidades de Emergência, sendo uma condição clínica comum, dramática pela dor envolvida e de abordagem não uniformizada pela diversidade de informações a respeito. Entre os métodos utilizados para o diagnóstico que foram apresentados a escolha do uso de TC é inicialmente superior, porque é um método que fornece imagens de seção transversal axial sem

o problema de sobreposição e possui uma melhor percepção para detectar calcificação do que a radiografias simples[1].

Técnicas de diagnóstico por imagem são frequentemente recorridas para casos de cálculos renais. Sendo mais relevante a utilização da TC no diagnóstico de patologias renais por permitir através das imagens a obtenção de várias fases de realce. Um comparativo entre o uso dos diferentes métodos de diagnóstico por imagem mostrou a eficiência no uso da TC. Sendo considerado o primeiro método complementar de diagnóstico não invasivo a obter imagens sem sobreposições de estruturas do interior do corpo humano [23]. A TC tornou-se bastante utilizada no diagnóstico de diversas patologias, incluindo a detecção de cálculos renais. O diagnóstico obtido através do exame interfere diretamente no tipo de tratamento, pelo fato do tratamento depender diretamente do tamanho e localização do cálculo. Entre as dificuldades encontradas no diagnóstico de cálculo renal, a mais frequente é a diferenciação do cálculo [17]. Para tal, a utilização de técnicas de visão computacional é de extrema valia no auxílio ao diagnóstico[27].

Dessa forma, o objetivo deste trabalho é propor um método para detecção de cálculos renais em imagens de tomografia computadorizada de Abdômen. Para isso, a metodologia proposta é dividida em 5 etapas. A primeira é a aquisição de imagens de TC, após este processo foram usadas técnicas de recorte. No pré-processamento foram avaliadas o Filtro da Mediana e o CLAHE, já para o processo de extração de características foram avaliados os descritores *DenseNet201*, *VGG16*, *ResNet50* e *Xception*. Na classificação, foram avaliados a *Multi-layer Perceptron* (MLP) e a *Random Forest* (RF). A comparação de todas as técnicas é feita em termos de Acurácia, Kappa, Precisão e Área sob a curva ROC (AUC).

Abaixo temos as principais contribuições deste trabalho:

- Uso de técnicas de aumento de dados para recorte das imagens dos exames para a criação da base de dados com 5.102 imagens renais.
- Avaliação de 4 redes pré-treinadas, 2 classificadores e 2 técnicas de pré-processamento na tarefa de detecção de calcificação.
- Desenvolvimento de uma aplicação para detecção de calcificações na região renal para auxiliar os profissionais de saúde na identificação dos mesmos.

O restante do artigo está organizado da seguinte forma: os trabalhos relacionados referentes ao tema apresentado na seção 2. O método proposto é apresentado na Seção 3. Os resultados experimentais são apresentados na Seção 4. Finalmente, as conclusões e os trabalhos futuros são apresentadas na Seção 5.

2. TRABALHOS RELACIONADOS

Nesta seção são apresentados alguns trabalhos referentes ao tema, representando as contribuições dos projetos mais relevantes relacionados a este artigo sobre a detecção de cálculo renal em imagens de Tomografia Computadorizada. O trabalho de [31] tem como objetivo desenvolver uma abordagem para a detecção e segmentação de cálculo renal, utilizando uma combinação de agrupamento multi-kernel k-means e classificação. A base de imagens utilizadas no trabalho foram coletadas em fontes da Internet disponíveis publicamente, contendo um total de 100 imagens

entre elas 40 imagens são normais, 30 são tumorais e 30 possui calcificações. Nos experimentos, utilizaram 805 imagens para treinamento e 20% de imagens para o processo de teste. O trabalho foi construído em quatro fases: pré-processamento, extração de características, classificação e segmentação. Na primeira fase foi eliminado o ruído presente nas imagens de entrada usando filtro da mediana. Após isto, foram extraídas as características com o descritor *Gray-Level Co-Occurrence Matrix* (GLCM) e em seguida a classificação das imagens em normal ou anormal usando uma rede neural. Por fim, nas imagens anormais é realizada a segmentação da calcificação e a parte do tumor separadamente usando multi Kernel K-means. Os resultados obtidos mostram que o sistema proposto atinge a precisão máxima de 99,61%.

O modelo de [43] contém três diretrizes que consiste primeiramente em selecionar imagens de ultrassom de rins, depois definir um modelo de detecção para localizar a área ocupada pelo rim na imagem e, por fim, diferenciar rins normais de anormais utilizando uma rede neural de fusão multifuncional (Mf-Net). Uma camada de fusão de vários descritores foram projetadas na Mf-Net para extrair características distintas para múltiplas visualizações de imagens. Os três componentes trabalham juntos para reconhecer automaticamente as anormalidades associadas aos rins nas 3.722 imagens de ultrassom abdominal com classificação e anotações de localização e sendo assim estabelecidas para treinar e avaliar o modelo. Os resultados mostram que o modelo de detecção de conjunto proposto atingiu uma precisão de classificação média de 94,67%.

O artigo de [40] avaliou três diferentes técnicas de pré-processamento para a remoção de ruído da imagem de TC de cálculo renal, sendo elas baseada em tamanho, forma e um algoritmo de limite híbrido. Nessa terceira técnica, o autor construiu um algoritmo que consiste em remover as regiões indesejadas usando dois algoritmos de limiarização com base no tamanho e localização, na qual encontram o maior objeto na imagem conseguindo assim eliminar o esqueleto ósseo, pois é o maior objeto entre todos os artefatos na imagem. O trabalho foca no pré-processamento das imagens com o objetivo de melhorar o desempenho da segmentação da região de interesse (ROI), removendo as regiões indesejadas, ruídos e perturbações. Utilizaram imagens de tomografia computadorizada transversal de abdômen digitalizadas de 75 pacientes com casos de cálculo renal, depois realizaram estimativa dos pontos de coordenadas na região do cálculo medida de forma independente por radiologistas especialistas para obter os dados de validação para a análise. Os resultados mostram que os métodos propostos de remoção de ruído calculados com base no limiar em tamanho (método I), em forma (método II) e limiarização híbrida (método III) apresentam sensibilidade de 90,91%, 92,93% e 68,69%, respectivamente.

A análise de TC é uma modalidade de imagem que tem potencial para melhorar a triagem e o diagnóstico de cálculos renais, inclusive da região rim-urina-barriga (KUB). Em [14] foi desenvolvido um método semiautomático que usava técnicas de processamento de imagem e geometria para detectar a borda e segmentar a área dos rins e consequentemente melhorar a detecção de cálculos renais. Esta técnica marca as calcificações detectadas e fornece uma saída que identifica o tamanho e a localização no rim com base na contagem de pixels. O programa foi testado em tomografia KUB de 39 pacientes do Hospital Imam Reza, no Irã, que foram divi-

dados em dois grupos com base na presença e ausência de cálculo renal. O programa obteve 84,61% de precisão.

Em [44] foi desenvolvido um método de detecção automática de cálculo renal utilizando imagens de tomografia computadorizada (TC) com técnicas de aprendizado profundo (DL), com o intuito de evitar o diagnóstico errôneo de cálculo perdido nas imagens de TC e minimizar os erros induzidos pelo médico. Um total de 1799 imagens foram usadas, tirando diferentes imagens de TC em corte transversal para cada pessoa. O modelo criado obteve uma precisão de 96,82% usando imagens de TC na detecção de cálculos renais. O trabalho consegue um bom desempenho em detectar com precisão as calcificações nos rins, mesmo de tamanhos pequenos.

Em [27] foi utilizada uma Rede Neural Artificial Heterogênea Modificada (HMANN) para a detecção precoce, segmentação e diagnóstico da insuficiência renal crônica, juntamente com o classificador Support Vector Machine e Multilayer Perceptron (MLP) com um algoritmo Backpropagation (BP). O algoritmo realizou um pré-processamento nas imagens de ultrassom e após isto a região de interesse do rim é segmentada. Na segmentação do rim, o método HMANN proposto atinge alta precisão e alcançou 97.5% de acurácia no trabalho.

Em [42] é feita a detecção de anomalias nos rins e mudança na estrutura do órgão em imagens de ultrassonografia. O processo foi iniciado com a restauração da imagem, o objetivo é reduzir ruído de manchas e, em seguida, é aplicada o filtro Gabor para suavização. Após esse processo, a imagem resultante é aprimorada usando a equalização do histograma. A imagem pré-processada e segmentada usando segmentação de conjunto de nível, e dois termos são usados. O primeiro termo de momentum e o segundo termo é baseado na propagação resiliente (Rprop). A região extraída do rim após a segmentação é aplicada às sub-bandas de wavelet Symlets, Biorthogonal (bio3.7, bio3.9 e bio4.4) e Daubechies para extrair os níveis de energia. Este nível de energia indica sobre a presença de calcificação naquele local particular, depois eles são treinados pela RNA Multilayer Perceptron (MLP) e Back Propagation (BP) para identificar o tipo de calcificação. Eles obtiveram uma precisão de 98,8%.

Em [11] foram coletadas imagens de tomografia computadorizada sem contraste abdominal (NCCT), de fevereiro de 2018 a abril de 2019. Essa coleta foi feita em três partes: um conjunto de dados de segmentação com 167 imagens, um conjunto de dados de classificação de hidronefrose com 282 e outro com um conjunto de dados de teste com 117. O modelo proposto foi dividido em quatro etapas, a primeira consistiu no desenvolvimento das redes 3D em U para segmentação de rim e seio renal. Após isto, as redes profundas de duplo caminho 3D para classificação de hidronefrose foram desenvolvidas. Os métodos de limiar foram usados para detectar e segmentar cálculos na região do seio renal. O tamanho do cálculo e o comprimento do trato foram calculados a partir da região segmentada do cálculo, e a partir destas propriedades a localização da calcificação foi determinada. O algoritmo de detecção de cálculos atingiu uma sensibilidade de 95,9%.

Em [22] foi criado um modelo para a detecção precoce do tipo de cálculo renal, em dados coletados de 936 pacientes com nefrolitíase no centro renal do Hospital Razi em Rasht de 2012 a 2016, e uma seleção de parâmetros foi realizada para identificar os mais relevantes para o trabalho

com o objetivo de fornecer um sistema assertivo. Na primeira etapa do trabalho foi realizado o pré-processamento dos dados para extrair as características relevantes, depois analisados com o software Weka, e vários modelos de mineração de dados foram usados para preparar um modelo preditivo. O artigo propôs quatro modelos baseados em ensemble learning para melhorar a precisão de cada algoritmo de aprendizagem. Além disso, uma nova técnica para combinar classificadores individuais na aprendizagem por conjunto foi proposta. Nesta técnica, para cada classificador individual, um peso é atribuído com base em algoritmo genético. O conhecimento gerado foi avaliado usando uma técnica de validação cruzada de 10 vezes com base em medidas padrão. O modelo final baseado em conjunto alcançou uma precisão de 97,1%.

3. METODOLOGIA PROPOSTA

Nesta seção, descrevemos a metodologia utilizada para extrair as características das imagens e a detecção de calcificações. Os estágios envolvidos nestas etapas são apresentados na Figura 1. A metodologia proposta está dividida em cinco etapas: A primeira consiste na aquisição das imagens coletadas em uma Clínica situada na cidade de Picos - Piauí. A segunda foca no recorte da região renal. Na terceira etapa, para o pré-processamento dos cortes foi avaliado o uso do Filtro da Mediana e a aplicação do CLAHE. Seguindo para a quarta etapa, foi realizado a extração de características das regiões do trato urinário utilizando os descritores DenseNet201, VGG16, ResNet50 e Xception. Por fim, na etapa de classificação, foram avaliados os classificadores MLP e RF.

3.1 Aquisição de Imagens

A base de imagens utilizada neste trabalho foi fornecida por uma clínica situada na cidade de Picos - Piauí. A base tem um conjunto de imagens formada por 10 exames de tomografia computadorizada, provenientes de 10 pacientes diferentes. Os exames possuem profundidade que varia de 3 até 29 fatias de tamanho 512x512, no formato DICOM (.dcm) convertidas para o formato em PNG, exemplo demonstrado na Figura 2. As regiões de cálculos renais presentes nessas imagens foram marcadas manualmente por um especialista. Os dados pessoais de identificação dos pacientes como nome, idade e peso foram removidos. Os valores apresentados de cada pixel nas imagens representa o valor de atenuação na escala de unidades de Hounsfield (HU) que está relacionada à composição do material naquele local dentro do corpo como ar que possui o valor de atenuação de 1000 HU e água 0 HU, essas informações ajudam a identificar distorções nas imagens e a presença do cálculo no local, pois o valor de densidade HU e o tamanho determina o tipo de cálculo e quão resistente se encontra, indica o tratamento correto e se é possível ser fragmentado[25].

3.2 Recorte Renal

Nesta etapa da metodologia proposta, as máscaras construídas foram utilizadas para obter a posição central da coordenada das calcificações, e assim realizar os cortes da região que contém a litíase renal, demonstrada na Figura 3. Para cada calcificação foram realizados 20 recortes de forma que a calcificação ficasse contida dentro da janela 64 x 64 recortada, no entanto em cada recorte a coordenada central da calcificação fica em diferente posição da imagem. Para

a obtenção das imagens sem calcificação, foram realizados recortes da região renal e da bexiga das imagens que não continham calcificação, como apresentado na Figura 4. Vale destacar que antes da divisão dos conjuntos de treino e teste, os exames foram separados, dessa forma não ficaram regiões de um mesmo exame presente no conjunto de treino e teste simultaneamente. No total foram geradas 2.790 amostras com calcificação e 2.312 sem calcificação.

3.3 Pré-Processamento

Nesta etapa, 2 métodos de pré-processamento foram avaliados nas imagens. O primeiro foi o CLAHE, ele foi aplicado nas imagens originais para realçar o contraste e para destacar a presença da calcificação, seu funcionamento é basicamente dividir cada imagem em blocos, em vez da amostra inteira para equalizar os histogramas dessas regiões, regulando a amplificação do ruídos para assim obter resultados significativos[9]. No pré-processamento foi definido a dimensão dos blocos em 8×8 . A escolha de áreas menores foi para reduzir a probabilidade de propagação de ruídos. Porém, quando o ruído é encontrado, é aplicado o limite de corte com valor padrão igual a 2. Assim, se em qualquer divisão do histograma forem encontrados ruídos superiores ao valor de corte, os mesmos serão removidos e distribuídos antes da equalização do histograma.

O outro filtro avaliado foi o da Mediana, pois a redução de ruído é uma atividade que melhora a qualidade dos exames ao reter as características da imagem e para facilitar a identificação do cálculo, pois podem ser facilmente confundidos com ruídos do tipo "sal e pimenta", "Gaussiano" e "aleatório"[8]. Sendo assim, se torna necessário o pré-processamento das imagens de TC para manter e tratar o baixo contraste e eliminar o ruído pontilhado. Este filtro não linear é bastante popular por ter um bom desempenho para remover valores de intensidade incoerente com os demais pixels da sua vizinhança. O processo de eliminação consiste em selecionar o pixel central de uma vizinhança $M \times M$ e substituir pelo valor mediano da janela correspondente, visto que os pixels de ruídos são considerados muito diferentes da mediana. Portanto, esta técnica foi aplicada nas imagens recortadas com dimensão 64 x 64, com uma janela 3 x 3.

3.4 Extração de Características

Após o pré-processamento nos recortes do trato urinário, as imagens foram utilizadas para extrair apenas as características das regiões indicadas. As arquiteturas utilizadas foram pré-treinadas na ImageNet para a extração de características e os resultados foram coletados após a sequência de convoluções e *pooling* [24], esta estratégia já foi utilizada em diversas aplicações de imagens [26, 6, 5, 4].

Os descritores utilizados foram: DenseNet201 [19], VGG16 [37], ResNet50 [18] e Xception [10]. O formato de entrada para todas as imagens foram *input_shape* = (64, 64, 3), exceto a Xception que o valor mínimo permitido de entrada na rede é o *input_shape* = (71, 71, 3), desta forma as imagens foram redimensionadas para o tamanho padrão de entrada da CNN na dimensão 299 x 299. Nesta etapa foram extraídas 2048 características das redes ResNet50 e Xception, 1920 da DenseNet201 e 512 da VGG16 [28].

3.5 Classificação

Nesta etapa é feita a classificação das características ex-

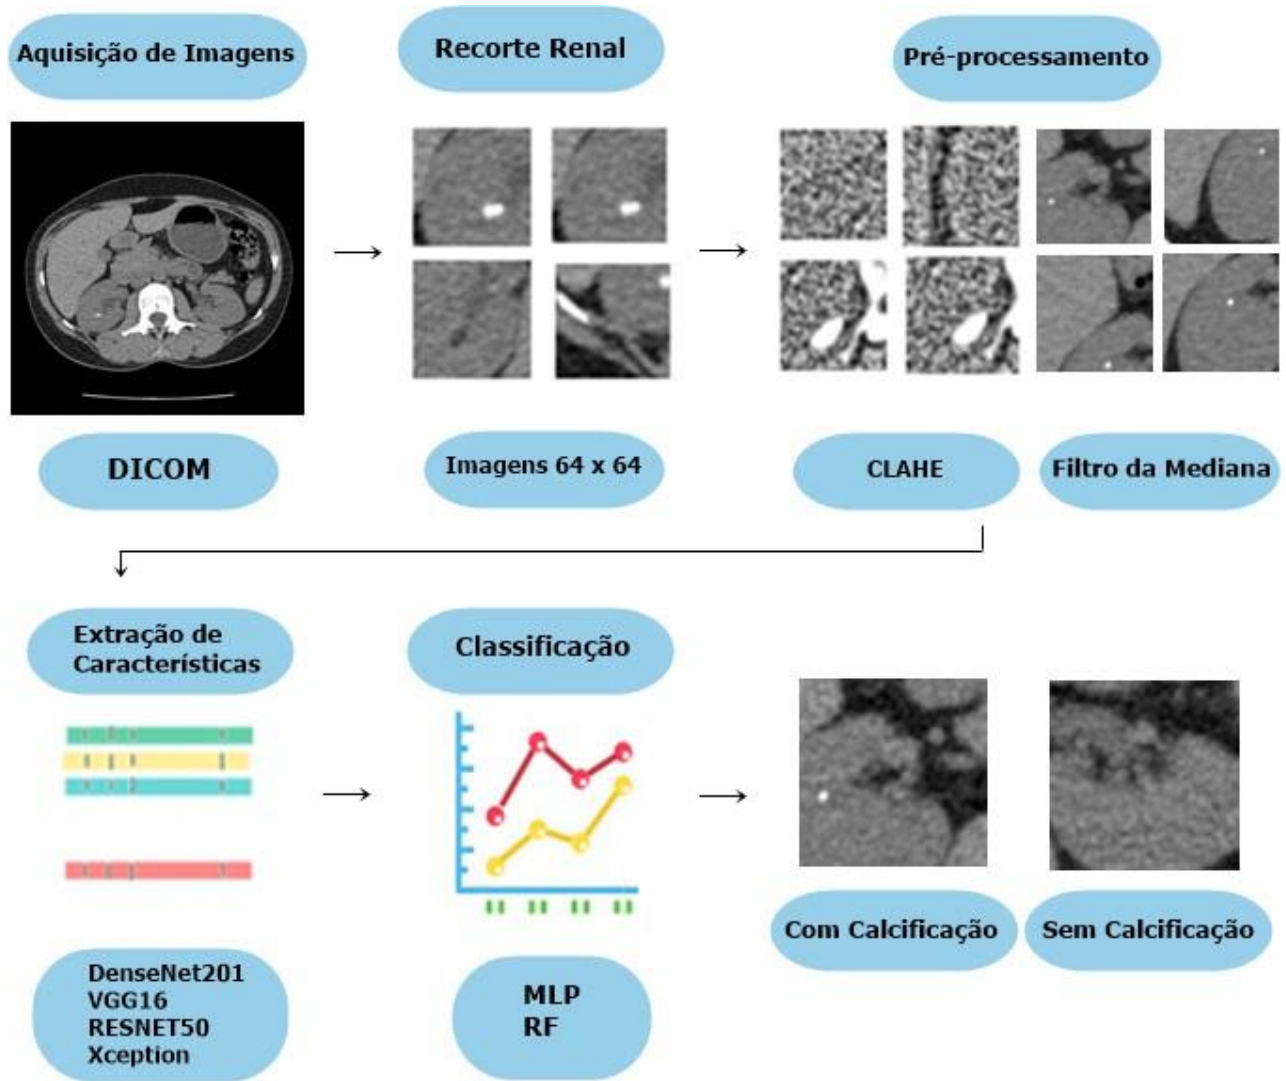


Figure 1: Fluxograma representativo do método proposto que está dividido em 5 etapas principais: Aquisição e imagens, recorte renal, pré-processamento, extração de características e classificação.




Figure 2: Exemplos de 4 fatias de um exame de TC com descolamento de 2mm. As fatias 2, 3 e 4 contêm calcificações




Figure 3: Cortes da região renal com calcificação e suas respectivas máscaras numa janela 64 x 64.

traídas na etapa anterior. Os classificadores utilizados foram: MLP [30] com os seguintes parâmetros: Número de épocas 300, 200 camadas ocultas, função de ativação Relu, coeficiente de aprendizado de 0.0001. Na RF, número de estimadores foram 250 e profundidade máxima de 50 [39].

4. RESULTADOS E DISCUSSÕES

Os códigos foram implementados em python, todos os modelos DL foram implementados usando Keras (ver-2.1.1) com um back-end do TensorFlow (versão 1.3.0) e todos os experimentos foram realizados em uma NVMe com 8 GB de memória RAM. Para o treinamento e avaliação dos métodos propostos selecionamos aleatoriamente 70% dos exames para o conjunto de treino e 30% para o conjunto de teste.




Figure 4: Cortes da região renal sem calcificação.

A Tabela 4 apresenta os melhores resultados e desempenho comparativo de cada descritor para as imagens (Sem Calcificação e Com Calcificação). Para isso, foram utilizadas as seguintes métricas: Acurácia (Ac), Kappa (Ka), Precisão (Pr) e Área Sob a Curva (AUC) - ROC [3].

Na Tabela 4, quando não foi utilizado nenhuma técnica de pré-processamento, a MLP obteve o melhor desempenho na classificação das imagens com os descritores ResNet50 e Xception, apresentando acurácia de 0,93. A MLP neste caso conseguiu os melhores resultados, porque esse classificador se adapta melhor para grande quantidade de características que são as extraídas pelas redes pré-treinadas. Foram extraídas 2048 características na última camada de *pooling* da ResNet50 e na Xception. Neste mesmo cenário, a RF obteve resultados superiores na ResNet50 nas métricas: Precisão com 0,82 e AUC de 0,88. A estrutura pré-treinada de camadas profundas ResNet50 e o classificador RF são co-

Table 1: Resultados obtidos para cada descritor (Imagens Originais X Filtro da Mediana X Clahe)

Imagens Originais						
Descritores	Classes	Classificadores	Acurácia	Kappa	Precisão	AUC
DenseNet201	Sem Calcificação x Com Calcificação	MLP	0,91	0,66	0,61	0,79
		RF	0,91	0,55	0,79	0,88
ResNet50	Sem Calcificação x Com Calcificação	MLP	0,93	0,74	0,73	0,85
		RF	0,92	0,70	0,82	0,88
VGG16	Sem Calcificação x Com Calcificação	MLP	0,91	0,66	0,68	0,82
		RF	0,92	0,68	0,82	0,86
Xception	Sem Calcificação X Com Calcificação	MLP	0,93	0,75	0,72	0,85
		RF	0,91	0,63	0,78	0,86
Imagens com o Filtro da Mediana						
Descritores	Classes	Classificadores	Acurácia	Kappa	Precisão	AUC
DenseNet201	Sem Calcificação x Com Calcificação	MLP	0,91	0,67	0,80	0,88
		RF	0,91	0,65	0,79	0,89
ResNet50	Sem Calcificação x Com Calcificação	MLP	0,93	0,73	0,71	0,84
		RF	0,92	0,69	0,82	0,88
VGG16	Sem Calcificação x Com Calcificação	MLP	0,90	0,65	0,71	0,84
		RF	0,92	0,69	0,82	0,88
Xception	Sem Calcificação x Com Calcificação	MLP	0,94	0,76	0,75	0,86
		RF	0,90	0,62	0,78	0,85
Imagens com a aplicação do CLAHE						
Descritores	Classes	Classificadores	Acurácia	Kappa	Precisão	AUC
DenseNet201	Sem Calcificação x Com Calcificação	MLP	0,89	0,63	0,60	0,78
		RF	0,89	0,65	0,80	0,86
ResNet50	Sem Calcificação x Com Calcificação	MLP	0,89	0,67	0,65	0,81
		RF	0,90	0,69	0,82	0,87
VGG16	Sem Calcificação x Com Calcificação	MLP	0,88	0,62	0,64	0,79
		RF	0,89	0,65	0,79	0,86
Xception	Sem Calcificação x Com Calcificação	MLP	0,87	0,58	0,54	0,75
		RF	0,86	0,54	0,73	0,84

nhecidos por serem relativamente flexíveis de serem otimizados, sendo assim podem atingir maiores valores de precisão e na quantificação da capacidade de classificação, dessa forma seu desempenho nas imagens sem pré-processamento foram bons.

No conjunto de imagens com o Filtro da Mediana, os resultados apresentados na Tabela 4 mostram que o melhor desempenho obtido foi do classificador MLP juntamente com o descritor Xception, alcançando uma Acurácia de 0,94 e Kappa de 0,76. Nota-se também que houve um aumento de desempenho nos descritores DenseNet201 com o classificador MLP, apresentando 0,80 de Precisão e na VGG16 com o classificador RF alcançando 0,88 de AUC. Esses resultados demonstram que a redução de ruído auxiliou positivamente na tomada de decisão das redes em diferenciar a presença do cálculo da região renal saudável [21]. O filtro da mediana é uma operação mais robusta do que a média aritmética para a remoção de ruídos, pois um único pixel de baixa relevância em uma vizinhança, não afetará significativamente o valor da mediana. Como o valor da mediana deverá ser o número de um dos pixels da janela da dimensão fornecida, então ele não criará novos valores de intensidades irreais quando o filtro cruzar uma borda[7]. Por esta razão, esta técnica é superior na preservação de bordas de objetos significativos e na remoção de pontos incoerentes em imagens do que outros filtros não-lineares [12].

Entre as técnicas avaliadas no pré-processamento, o melhor conjunto de imagens para utilizar na entrada das redes

são as imagens com o filtro da Mediana, pois suaviza os ruídos da imagem e evidencia a localização do cálculo. No quadro geral, a MLP performou melhor que a RF, possivelmente, porque a MLP possui um desempenho elevado para dados numéricos e com uma maior quantidade de atributos. Já em relação ao CLAHE, foi observado na Tabela 4 que o descritor ResNet50 com o classificador RF alcançou os melhores resultados, obtendo 0,90 de Acurácia e 0,87 de AUC.

Na etapa de extração de características entre as arquiteturas avaliadas, a ResNet50 e a Xception pré-treinadas obtiveram resultados superiores aos outros descritores. A Xception é uma rede neural convolucional profunda capaz de introduzir novas camadas iniciais, construídas a partir de camadas de convolução de profundidade e seguidas por uma camada de convolução pontual [3]. A combinação entre os blocos de profundidade e de ponto, juntamente com blocos residuais na Xception, sendo a ResNet50 também uma rede neural convolucional profunda que contém blocos residuais, torna suas estruturas fáceis de definir, modificar e otimizar[33].

No desempenho geral deste método, observou-se que houve uma diminuição na assertividade das redes na descrição da região de interesse, como as imagens de TC eram de baixo contraste sendo indicadas como a melhor forma de prever cálculos, o contraste aplicado pelo o equalizador CLAHE colocou em evidência os ruídos existentes na imagem e consequentemente ampliou-os, isto pode ser observado na Fi-

gura 5 (C), que a calcificação está menos aparente e há um aumento de pontos incertos [35].

A Figura 5 apresenta um exemplo de um recorte na imagem original do exame de TC juntamente com a aplicação do filtro da Mediana e do CLAHE. Na imagem original (A) constata-se alguns ruídos mínimos próximo ao cálculo, mas na imagem (B) percebe-se que o filtro da mediana realizou uma suavização desses pontos na qual a calcificação continua em destaque, mas a região externa dele os valores de intensidade estão em concordância com a vizinhança. Já na imagem (C), filtrada pelo CLAHE, é possível observar que a borda do cálculo está ofuscada e completamente preenchida com ruídos "sal e pimenta".




Figure 5: Recorte da região renal do paciente com calcificações. A (Imagem Original), B (Filtro da Mediana) e C (Clahe).

5. CONCLUSÃO E TRABALHOS FUTUROS

Neste trabalho, foi abordado o desenvolvimento de um método para detectar a presença de calcificações em tomografias computadorizadas. De acordo com os testes realizados, o filtro da mediana produziu melhores resultados em comparação ao usar diretamente as imagens originais, demonstrando que a extração de características com a redução de ruídos podem melhorar a precisão dos modelos na identificação das calcificações. Além disso, a MLP performou melhor que a RF na etapa de classificação, e a ResNet50 e Xception pré-treinadas foram os melhores descritores. A principal vantagem de se usar descritores neurais neste cenário é que a CNN aprende de forma autônoma a extrair características úteis para detectar a calcificação diretamente da imagem.

Como principais limitações temos o pequeno número de exames da base, mas como trabalho futuro pretendemos aumentar a quantidade de exames utilizados na criação e avaliação do método, ampliando o número de imagens para um melhor treinamento dos modelos. Outra limitação foi o uso

de parâmetros padrões nos classificadores, mas como trabalho futuro será realizada uma etapa de seleção de parâmetros, o que deverá melhorar os resultados ainda mais. Ainda como trabalho futuro, pretende-se considerar mais modalidades de imagem renal e os tipos de cálculos existentes, visando maior acurácia e sensibilidade.

6. REFERENCES

- [1] M. Abdel-Nasser and O. A. Omer. Ultrasound image enhancement using a deep learning architecture. In *International Conference on Advanced Intelligent Systems and Informatics*, pages 639–649. Springer, 2016.
- [2] M. Andreou and R. MacMahon. Renal colic in pregnancy: lithiasis or physiological hydronephrosis? *Urology*, 74(4):757–761, 2009.
- [3] F. H. Araújo, A. M. Santana, and P. d. A. S. Neto. Using machine learning to support healthcare professionals in making preauthorisation decisions. *International journal of medical informatics*, 94:1–7, 2016.
- [4] F. H. Araujo, R. R. Silva, F. N. Medeiros, D. D. Parkinson, A. Hexemer, C. M. Carneiro, and D. M. Ushizima. Reverse image search for scientific data within and beyond the visible spectrum. *Expert Systems with Applications*, 109:35–48, 2018.
- [5] F. H. Araujo, R. R. Silva, D. M. Ushizima, M. T. Rezende, C. M. Carneiro, A. G. Campos Bianchi, and F. N. Medeiros. Deep learning for cell image segmentation and ranking. *Computerized Medical Imaging and Graphics*, 72:13–21, 2019.
- [6] E. D. Carvalho, A. O. Filho, R. R. Silva, F. H. Araujo, J. O. Diniz, A. C. Silva, A. C. Paiva, and M. Gattass. Breast cancer diagnosis from histopathological images using textural features and cbir. *Artificial Intelligence in Medicine*, 105:101845, 2020.
- [7] E. Chandra and K. Kanagalakshmi. Noise elimination in fingerprint image using median filter. *Int. J. Adv. Netw. Appl*, 2(06):950–955, 2011.
- [8] C.-C. Chang, J.-Y. Hsiao, and C.-P. Hsieh. An adaptive median filter for image denoising. In *2008 Second International Symposium on Intelligent Information Technology Application*, volume 2, pages 346–350. IEEE, 2008.
- [9] Y. Chang, C. Jung, P. Ke, H. Song, and J. Hwang. Automatic contrast-limited adaptive histogram equalization with dual gamma correction. *Ieee Access*, 6:11782–11792, 2018.
- [10] F. Chollet. Xception: Deep learning with depthwise separable convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 1251–1258, 2017.
- [11] Y. Cui, Z. Sun, S. Ma, W. Liu, X. Wang, X. Zhang, and X. Wang. Automatic detection and scoring of kidney stones on noncontrast ct images using stone nephrolithometry: Combined deep learning and thresholding methods. *Molecular Imaging and Biology*, 23(3):436–445, 2021.
- [12] İ. Dinç, S. Dinç, M. Sigdel, M. S. Sigdel, R. S. Aygün, and M. L. Pusey. Dt-binarize: A decision tree based binarization for protein crystal images. In *Emerging trends in image processing, computer vision and*

- pattern recognition*, pages 183–199. Elsevier, 2015.
- [13] D. H. Diniz, N. Schor, and S. L. Blay. Stressful life events and painful recurrent colic of renal lithiasis. *The Journal of urology*, 176(6):2483–2487, 2006.
- [14] S. Ebrahimi and V. Y. Mariano. Image quality improvement in kidney stone detection on computed tomography images. *Journal of image and graphics*, 3(1):40, 2015.
- [15] D. C. Elton, E. B. Turkbey, P. J. Pickhardt, and R. M. Summers. A deep learning system for automated kidney stone detection and volumetric segmentation on non-contrast ct scans. *Medical Physics*, 2022.
- [16] A. B. Ferreira. Insuficiência renal aguda. *Anais da Faculdade de Medicina de Porto Alegre*, 19:181–192, 1959.
- [17] M. George and H. Anita. Analysis of kidney ultrasound images using deep learning and machine learning techniques: A review. *Pervasive Computing and Social Networking*, pages 183–199, 2022.
- [18] K. He, X. Zhang, S. Ren, and J. Sun. Deep residual learning for image recognition. In *Conference on Computer Vision and Pattern Recognition*, volume 2016-December, pages 770–778. IEEE Computer Society, 12 2016.
- [19] G. Huang, Z. Liu, L. Van Der Maaten, and K. Q. Weinberger. Densely connected convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 4700–4708, 2017.
- [20] C. M. Johnson, D. M. Wilson, W. M. O’Fallon, R. S. Malek, and L. T. Kurland. Renal stone epidemiology: a 25-year study in rochester, minnesota. *Kidney international*, 16(5):624–631, 1979.
- [21] J. Kawahara, A. BenTaieb, and G. Hamarneh. Deep features to classify skin lesions. In *2016 IEEE 13th international symposium on biomedical imaging (ISBI)*, pages 1397–1400. IEEE, 2016.
- [22] Y. Kazemi and S. A. Mirroshandel. A novel method for predicting kidney stone type using ensemble learning. *Artificial intelligence in medicine*, 84:117–126, 2018.
- [23] M. M. Khalil and P. Zanzonico. *Basic sciences of nuclear medicine*. Springer, 2011.
- [24] A. Krizhevsky, I. Sutskever, and G. E. Hinton. Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25:1097–1105, 2012.
- [25] M. Långkvist, J. Jendeberg, P. Thunberg, A. Loutfi, and M. Lidén. Computer aided detection of ureteral stones in thin slice computed tomography volumes using convolutional neural networks. *Computers in biology and medicine*, 97:153–160, 2018.
- [26] D. S. Luz, T. J. Lima, R. R. Silva, D. M. Magalhaes, and F. H. Araujo. Automatic detection metastasis in breast histopathological images based on ensemble learning and color adjustment. *Biomedical Signal Processing and Control*, 75:103564, 2022.
- [27] F. Ma, T. Sun, L. Liu, and H. Jing. Detection and diagnosis of chronic kidney disease using deep learning-based heterogeneous modified artificial neural network. *Future Generation Computer Systems*, 111:17–26, 2020.
- [28] D. Marmanis, M. Datcu, T. Esch, and U. Stilla. Deep learning earth observation classification using imagenet pretrained networks. *IEEE Geoscience and Remote Sensing Letters*, 13(1):105–109, 2015.
- [29] M. Memarsadeghi, G. Heinz-Peer, T. H. Helbich, C. Schaefer-Prokop, G. Kramer, M. Scharitzer, and M. Prokop. Unenhanced multi-detector row ct in patients suspected of having urinary stone disease: effect of section width on diagnosis. *Radiology*, 235(2):530–536, 2005.
- [30] P. R. Nicolas. *Scala for machine learning*. Packt Publishing Ltd, 2015.
- [31] A. Nithya, A. Appathurai, N. Venkatadri, D. Ramji, and C. A. Palagan. Kidney disease detection and segmentation using artificial neural network and multi-kernel k-means clustering for ultrasound images. *Measurement*, 149:106952, 2020.
- [32] R. Pecoits-Filho. Diagnóstico de doença renal crônica: avaliação da função renal. *J Bras Nefrol*, 26(3):4–5, 2004.
- [33] M. Rahimzadeh and A. Attar. A modified deep convolutional neural network for detecting covid-19 and pneumonia from chest x-ray images based on the concatenation of xception and resnet50v2. *Informatics in medicine unlocked*, 19:100360, 2020.
- [34] É. B. Rangel, S. A. Gomes, and I. P. Heilberg. Litíase renal no pré e pós-transplante renal. *Brazilian Journal of Transplantation*, 8(4):440–445, 2005.
- [35] S. Sahu, A. K. Singh, S. Ghrera, M. Elhoseny, et al. An approach for de-noising and contrast enhancement of retinal fundus image using clahe. *Optics & Laser Technology*, 110:87–98, 2019.
- [36] F. J. Sampaio and G. Di Biase Filho. Litíase renal. *Guia prático de urologia*. Rio de Janeiro: UERJ, pages 97–104, 2000.
- [37] K. Simonyan and A. Zisserman. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*, 2014.
- [38] E. F. Soares and G. S. Aragão. Algoritmo de apoio para tratamento da litíase renal. In *Anais do Congresso de Matemática aplicada à computacional*, pages 303–305, 2013.
- [39] S. Suthaharan. Machine learning models and algorithms for big data classification. *Integr. Ser. Inf. Syst*, 36:1–12, 2016.
- [40] N. Thein, K. Hamamoto, H. A. Nugroho, and T. B. Adji. A comparison of three preprocessing techniques for kidney stone segmentation in ct scan images. In *2018 11th Biomedical Engineering International Conference (BMEiCON)*, pages 1–5. IEEE, 2018.
- [41] C. M. L. P. C. B. P. J. S. R.-F. t. . l. r. a. ”Tiago Ferolla Nunes, Denise M. Brunetta. *Biblioteca Escolar Em Revista*, 43(3):272–282, 2010. DOI: <https://doi.org/10.11606/issn.2176-7262.v43i3p272-282>.
- [42] K. Viswanath and R. Gunasundari. Design and analysis performance of kidney stone detection from ultrasound image by level set segmentation and ann classification. In *2014 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*, pages 407–414. IEEE, 2014.
- [43] Y. Wu and Z. Yi. Automated detection of kidney

abnormalities using multi-feature fusion convolutional neural networks. *Knowledge-Based Systems*, 200:105873, 2020.

- [44] K. Yildirim, P. G. Bozdogan, M. Talo, O. Yildirim, M. Karabatak, and U. R. Acharya. Deep learning model for automated kidney stone detection using coronal ct images. *Computers in Biology and Medicine*, page 104569, 2021.