

Vitoria Karolina Ferreira de Sousa
Orientador: Prof. Dr. Flávio Henrique Duarte de Araújo

**Avaliação de Pré-Processamento e Redes
pré-treinadas para a Classificação de Cálculos
Renais em Imagens de Tomografia
Computadorizada**

Picos - PI
31 de julho de 2023

Vitoria Karolina Ferreira de Sousa
Orientador: Prof. Dr. Flávio Henrique Duarte de Araújo

Avaliação de Pré-Processamento e Redes pré-treinadas para a Classificação de Cálculos Renais em Imagens de Tomografia Computadorizada

Modelo de Trabalho de Conclusão de Curso em Bacharelado em Sistemas de Informação na Universidade Federal do Piauí. Este modelo está em conformidade com as normas ABNT.

Universidade Federal do Piauí
Campus Senador Heuvídio Nunes de Barros
Bacharelado em Sistemas de Informação

Picos - PI
31 de julho de 2023

FICHA CATALOGRÁFICA
Serviço de Processamento Técnico da Universidade Federal do Piauí
Biblioteca José Albano de Macêdo

S725a Sousa, Vitoria Karolina Ferreira de
Avaliação e pré-processamento e redes pré-treinadas para a classificação de cálculos renais em imagens de tomografia computadorizada [recurso eletrônico] / Vitoria Karolina Ferreira de Sousa - 2023.
36 f.

1 Arquivo em PDF
Indexado no catálogo *online* da biblioteca José Albano de Macêdo-CSHNB
Aberto a pesquisadores, com restrições da Biblioteca

Trabalho de Conclusão de Curso (Graduação) – Universidade Federal do Piauí, Bacharelado em Sistemas de Informação, Picos, 2023.
“Orientador : Prof. Dr. Flávio Henrique Duarte de Araújo”

1. Visão computacional. 2. Tomografia computadorizada. 3. Cálculo renal. 4. Extração de características. I. Araújo, Flávio Henrique Duarte de. II. Título.

CDD 004.7



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DO PIAUÍ
CAMPUS SENADOR HELVÍDIO NUNES DE BARROS
Curso de Sistemas de Informação



ATA DE APRESENTAÇÃO DE MONOGRAFIA

Período: 2023.1

Livro: 26, Folha: 01

Instala-se nesta data, 14 de agosto de 2023, a Banca Avaliadora da Monografia apresentada pelo(a) Acadêmico(a) **Vitoria Karolina Ferreira de Sousa**, sob o tema: "Avaliação de Pré-Processamento e Redes pré-treinadas para a Classificação de Cálculos Renais em Imagens de Tomografia Computadorizada", orientado(a) por mim **Flávio Henrique Duarte de Araújo**, composta pelos professores **Romuere Rodrigues Veloso e Silva** e **Thiago José Barbosa Lima**, presidida por mim, **Flávio Henrique Duarte de Araújo** nos termos do Regimento Interno do Curso de Sistemas de Informação e das normas pertinentes em vigor, como cumprimento do que estabelece a Matriz Curricular e o Projeto Pedagógico do Curso de Sistemas de Informação, devidamente aprovado pela UFPI. Para o que se estabelece:

- a) O Concluinte disporá de no mínimo 15 (quinze) minutos e no máximo 25 (vinte e cinco) minutos para a apresentação de sua produção, para o que se solicita a não interferência;
- b) Os componentes da Banca, encerrada a apresentação, disporão de até 25 (vinte e cinco) minutos para a arguição, para cada componente;
- c) Não será permitida nenhuma manifestação da parte da plenária, antes que seja declarada encerrada a sessão.

Declaramos aberta a sessão, oportunidade em que passamos a palavra ao concluinte para sua exposição, alertando-o para o tempo já anunciado.

APÓS ANÁLISE, CONSIDERA O(A) CONCLUINTE **VITORIA KAROLINA FERREIRA DE SOUSA**, COM CONCEITO/NOTA 8,8, (X) APROVADO () APROVADO COM RESSALVA () REPROVADO. CASO SEJA UMA DAS DUAS PRIMEIRAS OPÇÕES O CONCLUINTE FICA CONDICIONADO AO PLENO CUMPRIMENTO DAS PROPOSIÇÕES ANUNCIADAS PELA BANCA, NO PRAZO MÁXIMO DE 10 DIAS A CONTAR DESTA DATA, COMO TEMPO MÁXIMO PARA ENTREGA DA VERSÃO FINAL NA COORDENAÇÃO DO CURSO. O NÃO CUMPRIMENTO DAS PROPOSIÇÕES DA BANCA E DO PRAZO ACIMA ESTABELECIDO IMPLICARÁ EM REPROVAÇÃO.

Nada mais havendo a registrar encerro a presente sessão, da qual lavrou-se esta ATA que vai assinada por mim, pelos componentes desta Banca e pelo(a) Concluinte.

Picos, PI, 14 de agosto de 2023.

Flávio Henrique Duarte de Araújo
Presidente/Orientador(a)

Romuere Rodrigues Veloso e Silva

Membro/Avaliador(a)

Thiago José Barbosa Lima
Membro/Avaliador(a)

Vitoria Karolina Ferreira de Sousa
Concluinte

Agradecimentos

Agradeço primeiramente a Deus pela dádiva da vida e por ter chegado até aqui, por sempre ser meu guia nos momentos mais difíceis e também nas conquistas. Agradeço a minha família pelo apoio dado, principalmente a pessoa mais importante que tive a honra de ter sido filha e que sempre me incentivou a ir atrás dos meus sonhos fazendo de tudo para eu ter a educação que tive hoje, obrigado Luís Pereira (in memoriam) por ter acreditado em mim. Agradeço a minha mãe por ter sido a estrutura necessária para continuar.

Agradeço a todo o corpo de professores por todo o ensinamento compartilhado e em especial as mulheres mais importantes que tive durante a minha caminhada acadêmica: Patrícia Medyna, Patrícia Vieira e Juliana Carvalho. Cada uma desempenhou um papel que me marcou bastante de formas diversas e finalmente cheguei até aqui, devo agradecer por todos os conselhos e ensinamentos dado.

Em especial agradeço ao meu estimado orientador Flávio por ter sido muito mais que um simples professor e ter me aberto oportunidades grandiosas, além de ter acreditado neste trabalho e que juntos fizemos acontecer.

Aos amigos que me acompanharam cada um em seu momento durante esta minha jornada dentro e fora da universidade, Valderlândia, Lucas Jansen, Viviane, Açucena, Isaac, Raphael, Fabrícia, Kássio, Marcus Pinho, Lucas Lemos, Davi e Bruno, sem vocês nada disso seria possível. Agradeço a todos que, de forma direta ou indireta, participaram das minhas conquistas. A vocês o meu muito obrigada!

*"Faça as coisas o mais simples que você puder, porém não se restrinja às mais simples.-
Albert Einstein*

Resumo

O novo estilo de vida da sociedade atual com baixa priorização da qualidade de vida gerou um grande impacto na saúde. O aumento no número de casos de cálculos renais são exemplo disso, tornando essa patologia bastante comum na grande maioria dos consultórios de urologia e nefrologia. A mudança de hábitos da sociedade atual e uma não priorização à saúde formam um agravante a detecção tardia de cálculos renais, sendo que, uma detecção em estágio inicial é extremamente crucial para um melhor prognóstico, possibilitando um melhor tratamento a fim de evitar maiores problemas ao paciente, como por exemplo o excesso de radiação e procedimentos cirúrgicos. A calcificação renal é uma doença comum, geralmente detectada pelos médicos especialistas em exames de tomografia computadorizada (TC). Contudo, a análise desse tipo de exames ainda é uma tarefa desafiadora, o que torna um trabalho repetitivo, fadigante e sujeito a erros. Neste contexto propomos um método para detecção de calcificações, na região renal, em imagens de TC, que pode facilitar a tomada de decisão do especialista. Para o desenvolvimento desse método foi utilizada uma base de imagens privada com 887 amostras provenientes de 20 exames de diferentes pacientes. Este trabalho apresenta a avaliação dos métodos de pré-processamento: Filtro da Mediana e o CLAHE, com as redes convolucionais pré-treinadas 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. Conclui-se que com os testes realizados mostram que a extração de características com a redução de ruídos melhoram na precisão dos modelos no processo de identificação das calcificações.

Palavras-chaves: Tomografia computadorizada, Cálculo Renal, Visão Computacional, Extração de características, Classificação.

Abstract

The new lifestyle of today's society, with low prioritization of quality of life, has had a major impact on health. The increase in the number of cases of kidney stones is an example of this, making this pathology quite common in most urology and nephrology offices. Changing habits in today's society and not prioritizing health make late detection of kidney stones aggravating, and detection at an early stage is extremely crucial for a better prognosis, enabling better treatment in order to avoid further problems with patient, for example excess radiation and surgical procedures. Kidney calcification is a common condition, usually detected by specialist doctors using computed tomography (CT) scans. However, the analysis of this type of exam is still a challenging task, which makes it a repetitive, tiring and error-prone work. In this context, we propose a method for detecting calcifications in the renal region on CT images, which can facilitate the specialist's decision-making. For the development of this method, a private image base with 887 samples from 20 exams of different patients was used. This work presents the evaluation of the pre-processing methods: Median Filter and CLAHE, with the pre-trained convolutional networks DenseNet201, VGG16, RESNET50 and Xception, and the Multi-layer Perceptron (MLP) and Random Forest (RF) classifiers, for the detection of calcifications on CT images of the urinary tract. To evaluate the proposed method, 10 exams were used, totaling 2,790 images with calcifications and 2,312 images without calcifications. The evaluated scenario was (With Calcification x Without Calcification) and the best results were achieved with the Xception descriptor and the MLP classifier in the images with the Median Filter with an Accuracy of 0.94 and AUC of 0.86. With conclusion of the tests performed, it has been shown that the extraction of characteristics with the reduction of noise, improve the accuracy of the models in the process of identification of calcifications.

Lista de ilustrações

Figura 1 – Fluxograma representativo do método proposto que está dividido em 4 etapas principais.	20
Figura 2 – Amostra de 4 fatias de um exame de TC com descolamento de 2mm.	21
Figura 3 – Amostra de recorte da região renal com calcificação e sua respectiva máscara em janela 64 x 64.	22
Figura 4 – Cortes da região renal sem calcificação.	22
Figura 5 – Recorte da região renal do paciente com calcificações. A (Imagem Original), B (Filtro da Mediana) e C (CLAHE).	24

Lista de tabelas

Tabela 1 – Tabela de Trabalhos Relacionados	19
Tabela 2 – Resultados Obtidos utilizando as Imagens Originais.	25
Tabela 3 – Resultados Obtidos utilizando Filtro de Mediana.	26
Tabela 4 – Resultados Obtidos utilizando CLAHE.	26

Lista de abreviaturas e siglas

Au	Acurácia
AUC	Área sobre Curva
BP	<i>Back Propagation</i>
CLAHE	<i>Contrast limited adaptive histogram equalization</i>
CNN	<i>Convolutional Neural Network</i>
DL	<i>Deep Learning</i>
DICOM	<i>Digital Imaging and Communications in Medicine</i>
FPR	Taxa de Falso Positivo
TPR	Taxa de Verdadeiro Positivo
MLP	<i>Multi Layer Perceptron</i>
Pr	Precisão
PNG	<i>Portable Network Graphic</i>
PET	<i>Positron Emission Tomography</i>
RF	<i>Random Forest</i>
TC	Tomografia Computadorizada
UE	Urografia Excretora
HU	Unidades de <i>Hounsfield</i>

Sumário

1	Introdução	12
1.1	Objetivos Geral e Específicos	13
1.1.1	Objetivos Específicos	13
1.2	Estrutura do Trabalho	13
2	Referencial Teórico	14
2.1	Cálculo Renal	14
2.2	Tomografia Computadorizada	14
2.3	Visão Computacional	15
2.4	Redes Neurais Convolucionais	16
2.5	Métricas de Avaliação	16
3	Trabalhos Relacionados	18
4	Metodologia Proposta	20
4.1	Aquisição de Imagens	20
4.2	Pré-Processamento	21
4.3	Extração de Características	23
4.4	Classificação	23
5	Resultados	25
6	Conclusão	28
7	Publicações	29
	Referências	30
	Apêndices	34
	APÊNDICE A Apêndice	35

1 Introdução

O cálculo renal é uma doença comumente conhecida como pedra nos rins que provoca dores intensas. Ele possui um elevado impacto social e alto custo financeiro para tratamento, tendo em vista que afeta de 5 a 15% das pessoas em algum momento da vida, apresentando elevadas taxas de recorrência com maior prevalência nos homens do que em comparação as mulheres (SEBBEN; BRUM, 2007).

A incidência dessa doença aumenta na estação mais quente do ano, atingindo até 20% da população. Este agravante nos casos em períodos quentes se dá através de uma maior ocorrência de transpiração combinada a uma não ingestão de água suficientes para repor a quantidade perdida combinada a uma dieta rica em sódio (PRO-RENAL, 2020). Estima-se que 30% desses pacientes serão hospitalizados e submetidos a alguma intervenção cirúrgica associada à redução da produtividade (SOARES; ARAGÃO, 2013).

A cada 100 pessoas uma irá desenvolver cálculo renal ao longo da vida (RANGEL; GOMES; HEILBERG, 2005). Esta patologia é identificada como uma massa sólida formada por pequenos cristais, que podem ser encontrados tanto nos rins quanto em qualquer outro órgão do sistema urinário como: ureteres, a bexiga urinária e a uretra. Os países industrializados e de clima tropical têm uma maior incidência de cálculo renal, quando comparados aos países em desenvolvimento. Histórico familiar também é um dos fatores a serem observados (CURHAN et al., 1993).

A radiografia simples de abdômen e a urografia excretora (UE) foram por muito tempo considerados exames base para o diagnóstico, entretanto estes métodos foram substituídos pelo uso da tomografia computadorizada (TC) sem contraste de abdômen. A TC é considerada nos dias atuais o melhor método para detecção de cálculos renais (DYER; CHEN; ZAGORIA, 2001) e considerado exame padrão ouro no diagnóstico por disponibilizar aos profissionais avaliadores uma imagem mais consistente proporcionando imagens do corpo em diferentes ângulos e tamanhos e responsável pela identificação precoce dos cristais que formam o cálculo.

Uma das vantagens no uso da TC é o fornecimento da visualização da anatomia renal fiel ao real, também é capaz de fornecer parâmetros preditivos de sucesso para o tratamento como o seu tamanho, localização, densidade e a distância pele-cálculo. Além da não obrigatoriedade de aplicação de contraste, que é causador de reações alérgicas em boa parte dos casos. A TC oferece maiores benefícios diante outros exames em relação a diagnósticos precisos e o custo mais acessível comparado a exames de alta potência como por exemplo o *Positron Emission Tomography* (PET) que possui menor acessibilidade e maior custo de utilização.

A necessidade de um diagnóstico precoce destes casos é fundamental, pois os pacientes que apresentam cálculos renais constituem o grupo com maiores chances de obterem

perdas renais futuras, dado ao fato que os tratamentos realizados durante o período em que o paciente esteja com a patologia envolvem diversos fatores, entre elas, exposição a radiações em longo prazo. Por se tratar de uma patologia silenciosa, cerca de 60% dos portadores não tomam conhecimento de sua condição no estágio inicial da doença.

1.1 Objetivos Geral e Específicos

O objetivo geral deste estudo é propor um método de avaliações de pré-processamentos para a classificação de cálculos renais em imagens de tomografia computadorizada de abdômen.

1.1.1 Objetivos Específicos

Para que o objetivo geral seja plenamente alcançado, foram definidos os seguintes objetivos específicos:

- Criação de uma base de imagens de TC de abdômen com calcificações para o treinamento e avaliação do método proposto;
- Avaliação de redes pré-treinadas, classificadores e técnicas de pré-processamento na tarefa de detecção de cálculos renais;
- Análise comparativa de desempenho dos métodos desenvolvidos com métodos similares na literatura;

1.2 Estrutura do Trabalho

Este trabalho está organizado em 5 capítulos, além da introdução, divididos deste modo. Na seção 2 é mostrado o Referencial Teórico base para a construção deste estudo; Na seção 3, são apresentados os principais trabalhos relacionados a detecção de calcificações; Na seção 4 é listado todo o método proposto no desenvolvimento do estudo; Na seção 5 são listados todos os resultados obtidos durante o estudo. Na seção 6 são apresentadas as conclusões obtidas e as perspectivas de trabalhos futuros.

2 Referencial Teórico

Nesta seção será apresentado o referencial teórico que serve de base para o conteúdo abordado neste estudo.

2.1 Cálculo Renal

Os cálculos renais ou litíase urinária, chamados popularmente de pedra nos rins, são responsáveis por cerca de 65% dos casos de cálculos urinários, tendo como taxa de início de aparecimento dos 20 aos 40 anos e sendo em maior incidência no sexo masculino (BADER et al., 2012). A doença do cálculo renal não é apenas uma patologia do trato urinário, mas também está intimamente associada a anormalidades metabólicas e hábitos alimentares incorretos (RODRIGUES et al., 2020).

Fatores hereditários combinados a um estilo de vida onde não há uma priorização da saúde podem ser os maiores causadores da doença. A história familiar de litíase urinária aumenta em cerca de duas vezes a probabilidade de um indivíduo apresentar a doença. A dor tipo cólica é o sintoma mais frequente desta patologia e está diretamente associada à obstrução aguda do sistema coletor. Fortemente associado a dor, obstrução do trato urinário e perda da função renal (KEDDIS; RULE, 2013), há uma necessidade indiscutível em trabalhar formas de diagnósticos iniciais a fim de uma melhor qualidade de vida do acometido.

Um cálculo deve ser detectado, suas dimensões e volume determinados e sua composição ou fragilidade estimada para permitir a seleção do melhor método de tratamento. O diagnóstico é baseado através da história clínica do paciente combinado a exame de urina, e principalmente, por exames de imagem. A dificuldade em um diagnóstico em fase inicial se dá pela maioria dos casos serem assintomáticos ou apresentarem apenas pequenas dores na região lombar (LEVINE et al., 1997).

A TC tem sido cada vez mais utilizada principalmente em casos de cólica renal e é capaz de identificar quase todos os tipos de cálculos e de dilatação do ureter.

2.2 Tomografia Computadorizada

A TC revolucionou a radiologia diagnóstica e possibilitou um enorme avanço nos métodos de imagem. Surgida no início dos anos 70, inaugurou uma nova etapa na radiologia e no diagnóstico mais detalhado em exames de imagem. O uso da TC vem crescendo gradativamente, pois é uma tecnologia amplamente disponível e de fácil acesso aos pacientes. Das vantagens em seu uso podemos listar a sua rapidez em realização sendo bastante

utilizado em casos de emergências onde mostra boa qualidade das imagens (MOURÃO, 2018). A TC fornece imagens ideais para caracterizar uma calcificação e sua localização.

Os valores apresentados nas imagens de TC, cada píxel representa o valor de atenuação na escala de unidades de *Hounsfield*(HU) que está relacionada à composição do material naquele local dentro do corpo. Alguns exemplos são o ar que possui o valor de atenuação de 1000 HU e a água com 0 HU, essas informações ajudam a identificar distorções nas imagens e a presença do cálculo no local. O valor de densidade HU e o tamanho determinam o tipo de cálculo e quão resistente se encontra, auxiliando assim a indicar um tratamento correto e a sua possibilidade de fragmentação (LÄNGKVIST et al., 2018).

A TC vem desempenhando importante papel nos diagnósticos atribuídos a doenças renais e tratamentos das mesmas, sendo considerado por alguns como um divisor de águas no diagnóstico, antes atribuído a urografia excretora (SMITH; VARANELLI, 2000). Atualmente, é utilizada para medir a densidade e a distância entre os cálculos, variando entre 60% e 100% no diagnóstico (STREEM; YOST; DOLMATCH, 1997) (PREMINGER et al., 2005).

Por ser mais sensível em relação aos demais, é possível a determinação da localização precisa, seu tamanho e fornecer diagnósticos alternativos a dor lombar (VASWANI et al., 2002) (LONGO et al., 2001). A TC permite identificar cálculos de qualquer composição, exceto aqueles formados por inibidores de protease (SUNDARAM; SALTZMAN, 1999).

Em (PERKS et al., 2008) (EL-NAHAS et al., 2007) (ELBAHNASY et al., 1998), foram avaliados o tamanho, área e densidade do cálculo, a distância pele-cálculo e as medidas anatômicas da via, como comprimento, largura e altura infundibular e o ângulo. A disponibilidade proporcionada pelo avanço nos aparelhos propiciou um aumento significativo na taxa de remoção de cálculos e uma redução na morbidade durante o procedimento, levando a uma disseminação universal do método (KRAMBECK et al., 2006).

Baseada na reconstrução através de processos de computação dos dados obtidos através de varrões de uma mesma área, a TC utiliza um feixe de radiação X com alterações sucessivas de posição para obtenção de imagem digital. Esta constituída por elementos característicos de um volume (voxels)(MUKHERJEE; RAJAGOPALAN, 2007). Com os avanços das técnicas de visão computacional aplicadas a área médica, podem ser desenvolvidas técnicas para a detecção destes cálculos. Destacando-se no diagnóstico e aplicações intervencionistas, destes tendo como base a análise das imagens digitais obtidas (DESERNO et al., 2013).

2.3 Visão Computacional

A visão computacional é uma ciência implementada no início dos anos 70 e desde então vem revolucionando vários segmentos na qual é utilizada. Ela tem como objetivo a obtenção de algoritmos capazes de interpretar o conteúdo visual de imagens, envolvendo

principalmente a análise de imagens e reconhecimento de padrões.

Na primeira geração de máquinas de TC, uma reconstrução de imagem durava em cerca de 24h, mas a partir dos avanços nas técnicas de visão computacional e processamento de imagens foi reduzido a poucos segundos (SCHALLER; FLOHR, 2004). A visão computacional vem se mostrando uma ferramenta de grande valia na área médica por proporcionar avanços nas técnicas de diagnóstico, impactando diretamente na medicina atual.

2.4 Redes Neurais Convolucionais

As redes neurais convolucionais ou *Convolutional Neural Network* (CNN), são um tipo especial de rede neural multicamadas, considerada também como uma extensão natural das redes neurais para o tratamento de imagens. Reconhecida por aprender características que são invariáveis ao deslocamento, ou seja, filtros que são úteis em toda a imagem. As CNNs tem se mostrado bastante eficiente em muitas aplicações de visão computacional, como reconhecimento de objetos, segmentação e classificação.

Segundo (ARAÚJO et al., 2017), as CNNs se tornaram o novo padrão em visão computacional e apresentam algumas vantagens que consistem em: (a) na capacidade de extrair características relevantes através de aprendizado de transformações (*kernels*) e (b) depender de menor número de parâmetros de ajustes do que redes totalmente conectadas com o mesmo número de camadas ocultas. Neste cenário, há menos pesos a serem atualizados, porque cada unidade de uma camada não é conectada com todas as unidades da camada seguinte.

2.5 Métricas de Avaliação

Em projetos de visão computacional é crucial a utilização de métricas apropriadas ao problema em que está sendo utilizada. Na classificação, as métricas tem como objetivo medir o quão distante o modelo está da classificação ideal. Métricas estas que podemos listar sendo Acurácia (Au), Precisão (Pr), Área Sob a Curva (AUC) - ROC. Abaixo um pouco das métricas utilizadas neste trabalho:

A Acurácia (Au) nos mostra quantas das amostras foram de fato classificadas corretamente, independente da classe analisada. A área sobre curva ROC, é utilizada para avaliar a performance de um classificador com diferentes limiares de classificação. Construída medindo a Taxa de Falso Positivo (FPR) e a Taxa de Verdadeiro Positivo (TPR) para cada limiar de classificação possível. Quanto mais alto o limiar maior será a taxa de verdadeiro positivo (TPR), conseqüentemente a taxa de falso positivo (FPR) também será maior. A precisão é uma das métricas mais utilizadas e comuns na avaliação de modelos de classificação, é definida pela razão entre a quantidade de exemplos classificados corretamente

como positivos e o total de exemplos classificados como positivos ([SAMMUT; WEBB, 2011](#)).

3 Trabalhos Relacionados

Neste capítulo são apresentados alguns trabalhos referentes ao tema, representando as contribuições dos projetos mais relevantes relacionados a este artigo sobre a classificação para a detecção de cálculo renal em imagens de TC.

[Nithya et al. \(2020\)](#) apresentam uma abordagem para detecção e segmentação de cálculo renal, utilizando uma combinação de agrupamento multi-kernel k-means e classificação. A base de imagens utilizada no trabalho contém um total de 100 imagens, dentre elas 40 são normais, 30 são tumorais e 30 possuem calcificações. Nos experimentos, utilizaram 641 imagens para treinamento e 161 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) ([HARALICK; SHANMUGAM; DINSTEIN, 1973](#)) e em seguida realizou-se a classificação das imagens em normal ou anormal usando uma rede neural artificial. 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% na segmentação do tumor.

[Thein et al. \(2018\)](#) 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 ruídos 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.

No trabalho de [Viswanath e Gunasundari \(2014\)](#), 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, Bi-orthogonal (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 [Yildirim et al. \(2021\)](#) foi desenvolvido um método de detecção automática de cálculo renal utilizando imagens de TC com técnicas de aprendizado profundo Deep Learning (DL). Um total de 1799 amostras com diferentes imagens de TC de corte transversal foram utilizadas, o modelo criado obteve uma precisão de 96,82% na detecção de cálculos renais. O trabalho alcançou bom desempenho em detectar com precisão as calcificações nos rins, mesmo de tamanhos pequenos.

Na Tabela 1 podemos visualizar os métodos utilizados em cada trabalho, o seu resultado e a quantidade de amostras.

Tabela 1 – Tabela de Trabalhos Relacionados

Trabalho	Amostras	Método	Resultado
Viswanath e Gunasundari (2014)	500	(Rprop), Symlets, Biortogonal e wavelet Daubechies (MLP). Segmenta rins e detecta calcificações.	Precisão de 98,8%
Thein et al. (2018)	37.500	Limiarização por Forma, tamanho e limiarização Híbrida. Detecta e segmenta calcificações.	Sensibilidade de 90,91%, 92,93% e 68,69%.
Nithya et al. (2020)	100	Kmeans multi-kernel. Detecta e segmenta calcificações.	Precisão de 99.61%
Yildirim et al. (2021)	1.799	XResNet-50. Detecta calcificações.	Precisão de 96,82%

4 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. O método apresentado neste trabalho foi dividido em 4 etapas, que são: 1) Aquisição das Imagens; 2) Pré-Processamento; 3) Extração de características e 4) Classificação.

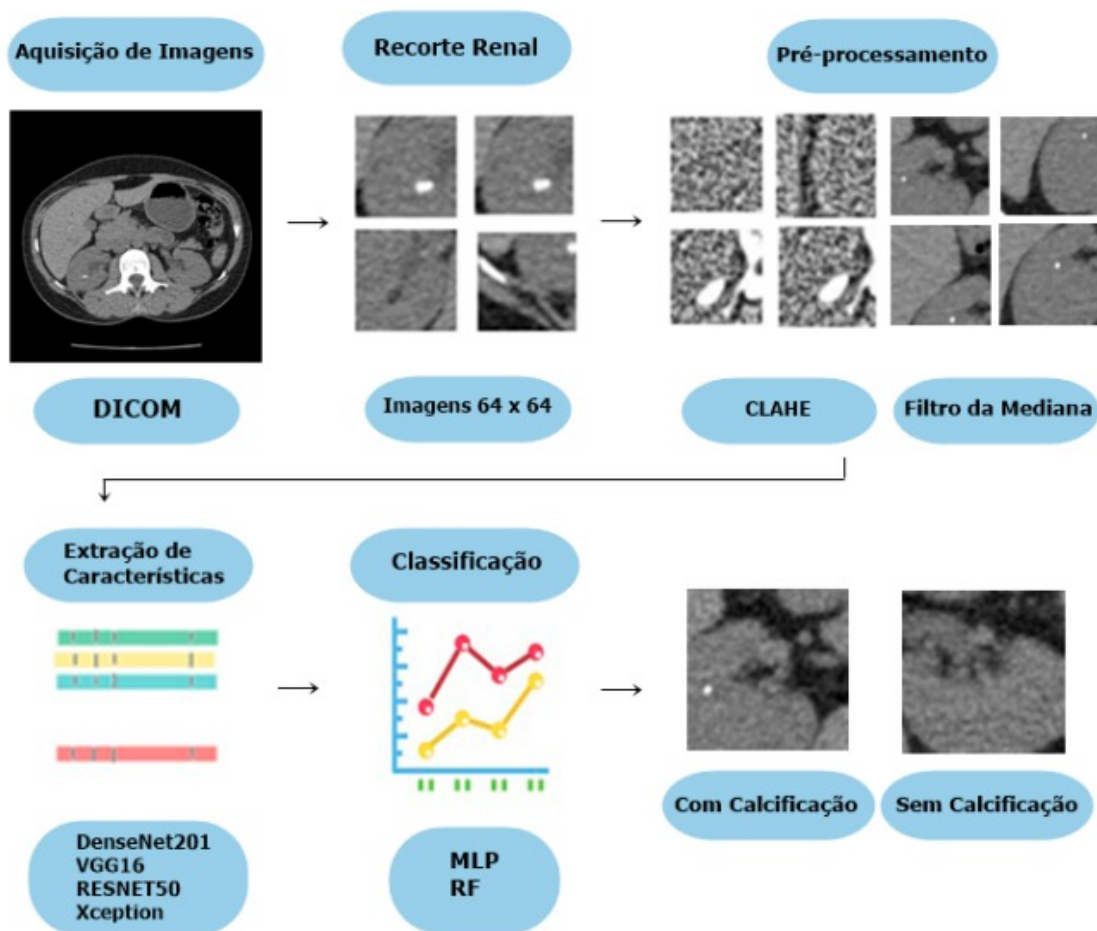


Figura 1 – Fluxograma representativo do método proposto que está dividido em 4 etapas principais.

4.1 Aquisição de Imagens

As imagens utilizadas para montagem da base utilizada neste trabalho foi fornecida por uma clínica situada na cidade de Picos - Piauí. Foram selecionados exames na qual há cálculos renais na região renal em sua maioria dentro dos rins ou no início do ureter. A base em maioria é formada por exames que contém cálculo renal. Essa base tem um conjunto

de imagens formada por 20 exames provenientes de 20 pacientes diferentes, totalizando 887 imagens e suas respectivas marcações das regiões de calcificação. Cada imagem possui tamanho de 512x512, com uma profundidade que varia por exame sendo entre 3 até 167 fatias. O formato original das imagens é *Digital Imaging and Communications in Medicine* (DICOM) de 16 bits, que pode variar de -32768 a +32767.

As regiões de cálculos renais presentes nessas imagens foram marcadas manualmente por um especialista, totalizando 532 imagens contendo calcificações. Os dados pessoais de identificação dos pacientes como nome, idade e peso foram removidos. Estas imagens presentes no conjunto de dados utilizado para execução deste trabalho requerem uma grande quantidade de recursos computacionais para a sua manipulação e após a coleta das imagens, foram feitas a marcação dos exames e a utilização de métodos para a conversão das imagens, originalmente em formato DICOM para o formato *Portable Network Graphic* (PNG), como mostra a Figura 2.




Figura 2 – Amostra de 4 fatias de um exame de TC com descolamento de 2mm.

4.2 Pré-Processamento

Assim que feito os cortes das imagens renais foram geradas máscaras nas calcificações sendo que cada recorte possui a sua respectiva máscara. As máscaras construídas foram utilizadas para obter a posição central da coordenada das calcificações, e assim realizar os cortes da região que contém o cálculo 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.

Na 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.




Figura 3 – Amostra de recorte da região renal com calcificação e sua respectiva máscara em janela 64 x 64.




Figura 4 – Cortes da região renal sem calcificação.

Para melhorar e tornar mais preciso os resultados no processo de detecção e classificação dos cálculos renais, aplicou-se 2 técnicas de pré-processamento, o Filtro de Mediana e *Contrast limited adaptive histogram equalization* (CLAHE). O CLAHE foi aplicado nas imagens originais para realçar o contraste e para destacar áreas candidatas à presença de calcificações, seu funcionamento é basicamente dividir cada imagem em blocos, em vez da amostra inteira para equalizar os histogramas dessas regiões, regulando a amplificação dos ruídos para assim obter resultados significativos (CHANG et al., 2018). No pré-processamento foi definido a dimensão dos blocos em 8X8, o motivo da escolha de

áreas menores foi para reduzir a probabilidade de propagação de ruído nas imagens.

O outro filtro utilizado foi o filtro 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” (CHANG; HSIAO; HSIEH, 2008). 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 64×64 , com uma janela 3×3 .

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”.

4.3 Extração de Características

Realizada a etapa de pré-processamento nos recortes da região renal, as imagens foram utilizadas para extrair as características das regiões indicadas. Para a extração de características, as arquiteturas utilizadas foram pré-treinadas na ImageNet e os resultados foram coletados após a sequência de convoluções e *pooling* (KRIZHEVSKY; SUTSKEVER; HINTON, 2012). Esta estratégia já foi utilizada em diversas aplicações de imagens.

Para tal, foram utilizados as CNNs: DenseNet201 (HUANG et al., 2017), VGG16 (SIMONYAN; ZISSERMAN, 2014), ResNet50 (HE et al., 2016) e Xception (CHOLLET, 2017). Em todas as imagens o formato de entrada foram $(64, 64, 3)$, exceto a *Xception* que tem como valor mínimo de entrada na rede permitido de $(71, 71, 3)$, desta forma as imagens foram redimensionadas para o tamanho padrão de entrada da CNN.

4.4 Classificação

Nesta etapa, as características extraídas na etapa anterior foram utilizadas para a classificação das imagens. Os classificadores utilizados foram a Multilayer Perceptron (MLP) (NICOLAS, 2015) com 200 neurônios na camada oculta e 300 épocas e o coeficiente de




Figura 5 – Recorte da região renal do paciente com calcificações. A (Imagem Original), B (Filtro da Mediana) e C (CLAHE).

aprendizado de 0.0001. Além da RF ([SUTHAHARAN, 2016](#)) com profundidade máxima em 50 e número de estimadores em 250.

5 Resultados

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. Nas Tabelas 2,3 e 4 apresentam 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.

Como mostra a Tabela 2, não foi utilizado nenhuma técnica de pré-processamento, a MLP obteve o melhor desempenho na classificação das imagens com os descritores ResNet 50 e Xception, apresentando acurácia de 0,93. A MLP conseguiu os melhores resultados, porque esse classificador se adapta melhor para grande quantidade de características que são 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 seguintes métricas, precisão com 0,82 e AUC de 0,88.

Tabela 2 – Resultados Obtidos utilizando as Imagens Originais.

Descritores	Classificadores	Acurácia	Kappa	Precisão	AUC
DenseNet201	MLP	0,91	0,66	0,61	0,79
	RF	0,91	0,55	0,79	0,88
ResNet50	MLP	0,93	0,74	0,73	0,85
	RF	0,92	0,70	0,82	0,88
VGG16	MLP	0,91	0,66	0,68	0,82
	RF	0,92	0,68	0,82	0,86
Xception	MLP	0,93	0,75	0,72	0,85
	RF	0,91	0,63	0,78	0,86

A estrutura pré-treinada de camadas profundas ResNet50 e o classificador RF são conhecidos por serem relativamente flexíveis de serem otimizados. Sendo assim, podem atingir maiores valores de precisão e na quantificação da capacidade de classificação. Desta forma, podemos concluir que seu desempenho nas imagens sem pré-processamento foram bons.

No conjunto de imagens com o Filtro da Mediana, os resultados apresentados na Tabela 3 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 (KAWAHARA; BENTAIEB; HAMARNEH, 2016).

Tabela 3 – Resultados Obtidos utilizando Filtro de Mediana.

Descritores	Classificadores	Acurácia	Kappa	Precisão	AUC
DenseNet201	MLP	0,91	0,67	0,80	0,88
	RF	0,91	0,65	0,79	0,89
ResNet50	MLP	0,93	0,73	0,71	0,84
	RF	0,92	0,69	0,82	0,88
VGG16	MLP	0,90	0,65	0,71	0,84
	RF	0,92	0,69	0,82	0,88
Xception	MLP	0,94	0,76	0,75	0,86
	RF	0,90	0,62	0,78	0,85

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 (CHANDRA; KANAGALAKSHMI, 2011). Podemos concluir que esta técnica é considerada superior na preservação de bordas de objetos significativos e na remoção de pontos incoerentes em imagens do que outros filtros não-lineares.

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 a CLAHE pode-se observar que o descritor ResNet50 com o classificador RF alcançou melhores resultados, obtendo 0.90 de acurácia e 0.87 de AUC como mostra a Tabela 4.

Tabela 4 – Resultados Obtidos utilizando CLAHE.

Descritores	Classificadores	Acurácia	Kappa	Precisão	AUC
DenseNet201	MLP	0,89	0,63	0,60	0,78
	RF	0,89	0,65	0,80	0,86
ResNet50	MLP	0,89	0,67	0,65	0,81
	RF	0,90	0,69	0,82	0,87
VGG16	MLP	0,88	0,62	0,64	0,79
	RF	0,89	0,65	0,79	0,86
Xception	MLP	0,87	0,58	0,54	0,75
	RF	0,86	0,54	0,73	0,84

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 que permite introduzir camadas iniciais a partir de camadas de convolução de profundidade, o que permite uma melhor otimização e modificação combinado ao uso da ResNet50. 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 (RAHIMZADEH; ATTAR, 2020).

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 equalizador CLAHE colocou em evidência os ruídos existentes na imagem e conseqüentemente ampliou-os, isto pode ser observado na Figura 5(C), que a calcificação está menos aparente e há um aumento de pontos incertos.

6 Conclusão

Neste trabalho apresentamos uma análise de técnicas de pré-processamento aplicadas a imagens de tomografia computadorizada de abdômen a fim da detecção de cálculos renais. Concluiu-se que a utilização de métodos para a redução de ruídos pode melhorar a precisão dos modelos na identificação das calcificações.

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 ResNet 50 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 automática 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, temos o uso de parâmetros padrões nos classificadores, mas como trabalho futuro será realizada uma etapa de seleção destes 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.

7 Publicações

Durante o desenvolvimento do estudo foi feita a publicação de um artigo na Revista de Computação e Sistemas (RSC).

- Camila Catiely de Sá Almondes, Vitoria Karolina Ferreira de Sousa, Flávio H. D. Araújo. Aprendizado Profundo para Detecção de Cálculos Renais em Imagens de Tomografia Computadorizada. Revista de Sistemas e Computação-RSC, v. 12, n. 1, 2022. (Qualis B4)

Referências

- ARAÚJO, F. H. et al. Redes neurais convolucionais com tensorflow: Teoria e prática. *SOCIEDADE BRASILEIRA DE COMPUTAÇÃO. III Escola Regional de Informática do Piauí. Livro Anais-Artigos e Minicursos*, Sociedade Brasileira de Computação, v. 1, p. 382–406, 2017. Citado na página 16.
- BADER, M. J. et al. Contemporary management of ureteral stones. *European urology*, Elsevier, v. 61, n. 4, p. 764–772, 2012. Citado na página 14.
- CHANDRA, E.; KANAGALAKSHMI, K. Noise elimination in fingerprint image using median filter. *Int. J. Adv. Netw. Appl*, Citeseer, v. 2, n. 06, p. 950–955, 2011. Citado na página 26.
- CHANG, C.-C.; HSIAO, J.-Y.; HSIEH, C.-P. An adaptive median filter for image denoising. In: *IEEE. 2008 Second international symposium on intelligent information technology application*. [S.l.], 2008. v. 2, p. 346–350. Citado na página 23.
- CHANG, Y. et al. Automatic contrast-limited adaptive histogram equalization with dual gamma correction. *Ieee Access*, IEEE, v. 6, p. 11782–11792, 2018. Citado na página 22.
- CHOLLET, F. Xception: Deep learning with depthwise separable convolutions. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2017. p. 1251–1258. Citado na página 23.
- CURHAN, G. C. et al. A prospective study of dietary calcium and other nutrients and the risk of symptomatic kidney stones. *New England journal of medicine*, Mass Medical Soc, v. 328, n. 12, p. 833–838, 1993. Citado na página 12.
- DESERNO, T. M. et al. Viewpoints on medical image processing. 2013. Citado na página 15.
- DYER, R. B.; CHEN, M. Y.; ZAGORIA, R. J. Intravenous urography: technique and interpretation. *Radiographics*, Radiological Society of North America, v. 21, n. 4, p. 799–824, 2001. Citado na página 12.
- EL-NAHAS, A. R. et al. A prospective multivariate analysis of factors predicting stone disintegration by extracorporeal shock wave lithotripsy: the value of high-resolution noncontrast computed tomography. *European urology*, Elsevier, v. 51, n. 6, p. 1688–1694, 2007. Citado na página 15.
- ELBAHNASY, A. M. et al. Lower-pole caliceal stone clearance after shockwave lithotripsy, percutaneous nephrolithotomy, and flexible ureteroscopy: impact of radiographic spatial anatomy. *Journal of endourology*, v. 12, n. 2, p. 113–119, 1998. Citado na página 15.
- HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. H. Textural features for image classification. *IEEE Transactions on systems, man, and cybernetics*, Ieee, n. 6, p. 610–621, 1973. Citado na página 18.

- HE, K. et al. Deep residual learning for image recognition. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2016. p. 770–778. Citado na página 23.
- HUANG, G. et al. Densely connected convolutional networks. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2017. p. 4700–4708. Citado na página 23.
- KAWAHARA, J.; BENTAIEB, A.; HAMARNEH, G. Deep features to classify skin lesions. In: IEEE. *2016 IEEE 13th international symposium on biomedical imaging (ISBI)*. [S.l.], 2016. p. 1397–1400. Citado na página 26.
- KEDDIS, M. T.; RULE, A. D. Nephrolithiasis and loss of kidney function. *Current opinion in nephrology and hypertension*, NIH Public Access, v. 22, n. 4, p. 390, 2013. Citado na página 14.
- KRAMBECK, A. E. et al. The evolution of ureteroscopy: a modern single-institution series. In: ELSEVIER. *Mayo Clinic Proceedings*. [S.l.], 2006. v. 81, n. 4, p. 468–473. Citado na página 15.
- KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, v. 25, 2012. Citado na página 23.
- LÄNGKVIST, M. et al. Computer aided detection of ureteral stones in thin slice computed tomography volumes using convolutional neural networks. *Computers in biology and medicine*, Elsevier, v. 97, p. 153–160, 2018. Citado na página 15.
- LEVINE, J. A. et al. Ureteral calculi in patients with flank pain: correlation of plain radiography with unenhanced helical ct. *Radiology*, v. 204, n. 1, p. 27–31, 1997. Citado na página 14.
- LONGO, J. et al. A prospective comparative study of non-contrast helical computed tomography and intravenous urogram for the assessment of renal colic. *Emergency Radiology*, Springer, v. 8, n. 5, p. 285–292, 2001. Citado na página 15.
- MOURÃO, A. P. *Tomografia computadorizada: tecnologias e aplicações*. [S.l.]: Difusão Editora, 2018. Citado na página 15.
- MUKHERJEE, D.; RAJAGOPALAN, S. *CT and MR angiography of the peripheral circulation: practical approach with clinical protocols*. [S.l.]: CRC Press, 2007. Citado na página 15.
- NICOLAS, P. R. *Scala for machine learning*. [S.l.]: Packt Publishing Ltd, 2015. Citado na página 23.
- NITHYA, A. et al. Kidney disease detection and segmentation using artificial neural network and multi-kernel k-means clustering for ultrasound images. *Measurement*, Elsevier, v. 149, p. 106952, 2020. Citado na página 18.
- PERKS, A. E. et al. Stone attenuation and skin-to-stone distance on computed tomography predicts for stone fragmentation by shock wave lithotripsy. *Urology*, Elsevier, v. 72, n. 4, p. 765–769, 2008. Citado na página 15.

- PREMINGER, G. M. et al. Chapter 1: Aua guideline on management of staghorn calculi: diagnosis and treatment recommendations. *The Journal of urology*, Wolters Kluwer Philadelphia, PA, v. 173, n. 6, p. 1991–2000, 2005. Citado na página 15.
- PRO-RENAL, I. *Casos de pedras nos rins têm mais incidência no verão*. 2020. Disponível em: <<https://www.pro-renal.org.br/2019/07/01/casos-de-pedras-nos-rins-tem-mais-incidencia-no-verao/>>. Citado na página 12.
- RAHIMZADEH, M.; ATTAR, A. 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*, Elsevier, v. 19, p. 100360, 2020. Citado na página 27.
- RANGEL, É. B.; GOMES, S. A.; HEILBERG, I. P. Litíase renal no pré e pós-transplante renal. *Brazilian Journal of Transplantation*, v. 8, n. 4, p. 440–445, 2005. Citado na página 12.
- RODRIGUES, F. G. et al. Dietary pattern analysis among stone formers: resemblance to a dash-style diet. *Brazilian Journal of Nephrology*, SciELO Brasil, v. 42, p. 338–348, 2020. Citado na página 14.
- SAMMUT, C.; WEBB, G. I. *Encyclopedia of machine learning*. [S.l.]: Springer Science & Business Media, 2011. Citado na página 17.
- SCHALLER, S.; FLOHR, T. Computed tomography—past, present and future. In: *Multislice CT*. [S.l.]: Springer, 2004. p. 3–17. Citado na página 16.
- SEBBEN, S.; BRUM, S. Urolitíase e fatores associados. *Arq Catarin Med*, v. 36, n. 2, p. 99–106, 2007. Citado na página 12.
- SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*, 2014. Citado na página 23.
- SMITH, R. C.; VARANELLI, M. Diagnosis and management of acute ureterolithiasis: Ct is truth. *American Journal of Roentgenology*, Am Roentgen Ray Soc, v. 175, n. 1, p. 3–6, 2000. Citado na página 15.
- SOARES, E. F.; ARAGÃO, G. S. Algoritmo de apoio para tratamento da litíase renal. In: *Anais do Congresso de Matemática aplicada à computacional*. [S.l.: s.n.], 2013. p. 303–305. Citado na página 12.
- STREEM, S. B.; YOST, A.; DOLMATCH, B. Combination “sandwich” therapy for extensive renal calculi in 100 consecutive patients: immediate, long-term and stratified results from a 10-year experience. *The Journal of urology*, Elsevier, v. 158, n. 2, p. 342–345, 1997. Citado na página 15.
- SUNDARAM, C. P.; SALTZMAN, B. Urolithiasis associated with protease inhibitors. *Journal of endourology*, v. 13, n. 4, p. 309–312, 1999. Citado na página 15.
- SUTHAHARAN, S. Machine learning models and algorithms for big data classification. *Integr. Ser. Inf. Syst*, Springer, v. 36, p. 1–12, 2016. Citado na página 24.

THEIN, N. et al. A comparison of three preprocessing techniques for kidney stone segmentation in ct scan images. In: IEEE. *2018 11th Biomedical Engineering International Conference (BMEiCON)*. [S.l.], 2018. p. 1–5. Citado na página 18.

VASWANI, K. K. et al. Ureterolithiasis: classical and atypical findings on unenhanced helical computed tomography. *Emergency radiology*, Springer, v. 9, n. 1, p. 60–66, 2002. Citado na página 15.

VISWANATH, K.; GUNASUNDARI, R. Design and analysis performance of kidney stone detection from ultrasound image by level set segmentation and ann classification. In: IEEE. *2014 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*. [S.l.], 2014. p. 407–414. Citado na página 18.

YILDIRIM, K. et al. Deep learning model for automated kidney stone detection using coronal ct images. *Computers in biology and medicine*, Elsevier, v. 135, p. 104569, 2021. Citado na página 19.

Apêndices

APÊNDICE A – Apêndice



**TERMO DE AUTORIZAÇÃO PARA PUBLICAÇÃO DIGITAL NA BIBLIOTECA
“JOSÉ ALBANO DE MACEDO”**

Identificação do Tipo de Documento

- () Tese
() Dissertação
(X) Monografia
() Artigo

Eu, **Vitoria Karolina Ferreira de Sousa**, autorizo com base na Lei Federal nº 9.610 de 19 de Fevereiro de 1998 e na Lei nº 10.973 de 02 de dezembro de 2004, a biblioteca da Universidade Federal do Piauí a divulgar, gratuitamente, sem ressarcimento de direitos autorais, o texto integral da publicação **Avaliação de Pré-Processamento e Redes Pré-Treinadas para Classificação de Cálculos Renais em Imagens de Tomografia Computadorizada** _____

_____ de minha autoria, em formato PDF, para fins de leitura e/ou impressão, pela internet a título de divulgação da produção científica gerada pela Universidade.

Picos-PI 29 de _____ agosto _____ de 2023.

Vitoria Karolina Ferreira de Sousa

Assinatura