

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

Thiago Lima¹, Camila Catiely², Vitoria Sousa³, Rodrigo Veras^{1,4},
Flávio Araújo^{1,2,3}

¹Universidade Federal do Piauí – (UFPI) – Teresina – PI – Brasil
Programa de Pós-graduação em Ciência da Computação – Associação UFMA/UFPI

²Programa de Pós Graduação em Engenharia Elétrica,
Universidade Federal do Piauí - Teresina, Brasil

³Curso de Sistemas de Informação,
Universidade Federal do Piauí - Picos, Brasil

⁴Departamento de Computação,
Universidade Federal do Piauí - Teresina, Brasil

{thiagobjb12, vivikarolfe, rveras, flavio86}@ufpi.edu.br,

{cctiely97}@gmail.com

Abstract. *Kidney calcification is a common condition, usually detected by specialist doctors using computed tomography (CT) scans. However, analyzing this type of exam is still challenging, making it repetitive, tiring, and error-prone. In this context, we propose an automatic method for detecting calcifications in the renal region on CT images, which may facilitate the specialist's decision-making process. For the development of this method, a private image base with 887 samples from 20 exams of different patients was used. The images were segmented using the Mask-RCNN, and for the calcification detection step, we evaluated four YOLOv5 models with different sizes of the input image. The model that stood out was YOLOv5n with an input size of 640×640 , obtaining a mAP₅₀ of 0.89, precision of 0.87, and recall of 0.85.*

Resumo. *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. As imagens foram segmentadas utilizando a Mask-RCNN e para etapa de detecção das calcificação, avaliamos quatro modelos YOLOv5 com diferentes tamanhos da imagem de entrada. O modelo que se destacou foi a YOLOv5n com tamanho de entrada 640×640 , obtendo um mAP₅₀ de 0,89, precisão de 0,87 e recall de 0,85.*

1. Introdução

O cálculo renal é 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. A prevalência é maior nos homens do que em comparação as mulheres e estima-se que 30% desses pacientes serão hospitalizados e submetidos a alguma intervenção cirúrgica associada à redução da produtividade [Soares and Aragão 2013].

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. da região renal. Os países industrializados e de clima tropical têm uma maior incidência de cálculo renal, quando comparados aos países em desenvolvimento. Fatores como o tipo de alimentação rico em sódio, altas temperaturas, perda de água através do suor, pouca ingestão de água, podem influenciar significativamente para o desenvolvimento desta doença. A cada 100 pessoas uma irá desenvolver cálculo renal ao longo da vida [Rangel et al. 2005].

Os sintomas apresentado por esta patologia, normalmente surgem de forma repentina, quando a calcificação se desloca pelas vias urinárias, provocando cólica, náuseas, vômitos, ardência para urinar, febre, calafrios e suor excessivo, o que deve ser tratada o mais rápido possível [Pecoits-Filho 2004]. Os cálculos que não apresentam sintomas podem ser identificados em exames de rotina, por um urologista.

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 [Tiago Ferolla Nunes 2010]. Entretanto, exames de imagens médicas como ultrassonografia, radiografia e tomografia computadorizada (TC) são essenciais para a identificação de calcificações. Neste contexto os exames de TC se destacam, pois 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 radiografias simples [Memarsadeghi et al. 2005].

O detecção precoce e o tratamento da calcificação renal em estágio inicial, aumentam as chances dos pacientes a não submeterem por procedimentos cirúrgicos. Com isso, ferramentas computacional denominadas *Computer-Aided Detection (CAD)* têm sido amplamente exploradas [Masood et al. 2018]. Na detecção de calcificação o grande desafio é determinar a localização precisa dos cristais, pois em seu estado inicial podem ser imperceptíveis a olho nu.

Neste trabalho, propomos um método para a detecção de cálculos renais em imagens de TC de abdômen. Para isso, a metodologia foi dividida em três etapas: 1) aquisição de imagens; 2) segmentação do sistema urinário e localização do centroide da região renal, utilizando a Mask-RCNN; e 3) detecção das calcificações, nesta última etapa avaliamos 4 arquitetura derivadas da YOLOv5 e diferentes tamanhos de entrada de imagens.

As principais contribuições deste trabalho foram: 1) Avaliação de uma rede de segmentação de instâncias, a Mask-RCNN para segmentação do sistema urinário; 2) Uma análise dos quatro modelos de detecção de objetos baseados na YOLOv5, na tarefa de detecção de calcificações com imagens segmentadas e não segmentadas; e 3) Avaliação

do impacto do uso de diferentes tamanhos de imagens e da segmentação da região renal na detecção das calcificações.

O restante do artigo está dividido em quatro seções principais: A seção 2 compreende uma síntese dos trabalhos relacionados. A seção 3 detalha o método proposto para detecção de calcificação em imagens de TC. Na seção 4, os resultados obtidos nos experimentos são apresentados e discutidos. Por fim, a seção 5 apresenta as conclusões e limitações deste estudo e proposta de trabalhos futuros.

2. Trabalhos relacionados

Nos últimos anos, inúmeras técnicas computacionais têm sido aplicadas na detecção de patologias em imagens de TC, a fim de auxiliar o trabalho de especialistas na busca pelo diagnóstico precoce e ao mesmo tempo possibilitando uma segunda opinião. Nesse cenário, técnicas para segmentação de região de interesse, detecção e classificação tem tido um bom destaque na literatura. As abordagens de *Deep Learning* ganhou maior notoriedade nos últimos anos, principalmente por apresentar resultados satisfatórios quando se comparados com abordagens clássicas.

A seleção dos trabalhos foi realizada em três bases de dados distintas: *Scopus*, *Science Direct* e *IEEE Xplore*. As strings de busca utilizadas foram: *kidney stone detection*, *kidney stone segmentation*, *deep learning for kidney diseases* e *automated kidney stone detection*. Utilizamos como critérios de inclusão e exclusão o ano de publicação, sendo que foram analisados artigos publicados a partir de 2014.

A Tabela 1 apresenta um resumo dos trabalhos relacionados. É destacado o nome do autor, ano de publicação, quantidade de amostras utilizadas, número de pacientes, método aplicado e melhor resultado obtido. Como pode ser observado na literatura, alguns trabalhos utilizam métodos de limiarização e morfologia matemática, pois necessitam remover os ossos ou outros tipos de tumores nas imagens, e com isso o método de segmentação possuem suas limitações. As calcificações podem se assemelhar com outras estruturas e neste sentido técnicas de segmentação podem ser utilizadas para uma melhor precisão na detecção das calcificações. Ainda de acordo com a literatura, podemos observar que ao segmentar a região renal, o processo de detecção das calcificações torna se mais preciso e eficiente.

Tabela 1. Resumo dos trabalhos relacionados.

Trabalho	Amostras	Pacientes	Método	Resultado
[Viswanath and Gunasundari 2014]	500	-	(Rprop), Symlets, Biortogonal e wavelet Daubechies (MLP). Segmenta rins e detecta calcificações.	Precisão de 98,8%
[Ebrahimi and Mariano 2015]	1.500	39	Detecção de Bordas. Segmenta rins e detecta calcificações.	Precisão de 84,61%
[Thein et al. 2018]	37.500	75	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%.
[Cui et al. 2021]	334	-	U-Nets 3D. Segmenta rins e detecta calcificações.	Sensibilidade de 95,9%.
[Yildirim et al. 2021]	1.799	433	XResNet-50. Detecta calcificações.	Precisão de 96,82%
[Parvathi and Jonnadula 2022]	-	30	U-net e Mask-RCNN. Segmenta rins e detecta calcificações.	IOU de 0,875
[Bayram et al. 2022]	1280	-	YOLOv7, YOLOv7 Tiny. Detecta Rins e calcificações.	mAP.05 de 0,85, Precisão de 0,882, Sensibilidade de 0,829 e Pontuação F1 de 0,854

A literatura mais recente se concentra no uso do modelo YOLOv7 e suas variações para problemas de detecção de objetos e de calcificações. No entanto, para treinar esses

tipos de arquitetura é necessário um grande número de amostras. A arquitetura YOLOv7 possui algumas limitações, como, por exemplo, a incapacidade de detectar objetos em diferentes escalas. Desta forma, neste trabalho, foram investigadas as arquiteturas YOLOv5 para a detecção de cálculos renais em imagens. Para tornar o método mais eficiente, utilizamos as redes YOLOv5 pré-treinadas, que apresentou um bom desempenho, principalmente quando dispõem de um número menor de amostras de treinamento.

3. Materiais e métodos

A metodologia proposta está dividida em três etapas como mostra a Figura 1: 1) aquisição de imagens; 2) segmentação do sistema urinário e localização do centroide da região renal; e 3) detecção das calcificações.

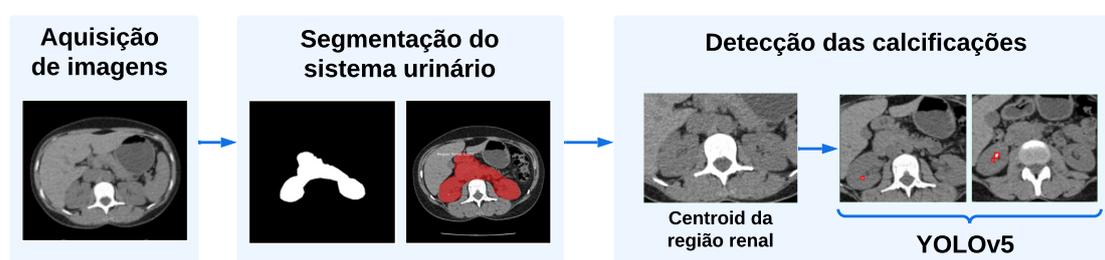


Figura 1. Fluxograma representativo do método proposto que está dividido em 3 etapas principais: aquisição de imagens, segmentação do sistema urinário e localização do centroide da região renal e detecção das calcificações.

3.1. Aquisição de Imagens

A base de imagens utilizada neste trabalho foi fornecida por uma clínica situada na cidade de Picos no estado do Piauí. O conjunto de imagens é formada por 20 exames de TC do abdômen provenientes de 20 pacientes diferentes, com 887 amostras e suas respectivas marcações das regiões de calcificação. Os exames possuem profundidade que varia de 3 até 167 fatias de tamanho 512×512 . O formato original das imagens é DICOM de 16 bits, que pode variar de -32768 a $+32767$. Para utilizar a YOLOv5 foi necessário converter as fatias para o formato PNG, onde os valores negativos foram convertidos para 0 e valores positivos foram convertidos proporcionalmente para o intervalo de 0 e 255, reescalando para inteiros positivos de 8 bits. 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.

3.2. Segmentação do Sistema Urinário

O sistema urinário é constituído pelos rins, o ureter e a bexiga, e as calcificações podem ser encontradas nestes órgãos, como demonstrado na Figura 2. Desta forma, o primeiro passo da metodologia proposta é a segmentação dessas regiões para delimitar a área de investigação das calcificações. Nesta etapa, as regiões que se encontram calcificações foram definidas como a classe: Região Renal.



Figura 2. Detecção da região renal no sistema urinário. As regiões em vermelho representam as áreas da região renal marcadas pela Mask-RCNN.

A segmentação foi realizada pela Mask-RCNN, pois a estrutura é leve, rápida e confiável para segmentação semântica em nível de pixel [He et al. 2017]. É uma estrutura que se divide em duas etapas: a primeira etapa a rede escaneia a imagem gerando áreas com probabilidade de conter um objeto. E a segunda etapa classifica as áreas geradas na primeira etapa, gerando caixas delimitadoras e máscaras. Neste contexto, a Mask-RCNN é bastante indicada para seleções de objetos da região renal como pedras e tumores, que costumam aparecer como erupções nas imagens renais e também por apresentar bons resultados nestes cenários, relativamente em média 80% a 99% [Parvathi and Jonnadula 2022].

Além das etapas que envolvem a segmentação de objetos através da Mask-RCNN, temos outro fator importante que é o processo de definição de um limiar. A escolha do limiar que considera duas métricas como critério de avaliação na detecção de objetos: a precisão e a pontuação F1 [Girshick et al. 2014]. Portanto, para este trabalho utilizamos um limiar de 0,5, onde essa escolha se deu com base em testes empíricos e com base na literatura, pois muitos trabalhos utilizam-se desse mesmo limiar, como [Xu et al. 2020], [Zhao et al. 2018] e [Prasetyo et al. 2020].

A Figura 3 apresenta um exemplo do processo de segmentação da renal. A primeira imagem apresenta uma área da região de interesse que foi detectada com a Mask-RCNN. Na segunda imagem temos a máscara gerada a partir dessa área da região de interesse. Em seguida, na terceira imagem temos uma janela 298×298 contendo apenas a região de interesse. O tamanho da janela foi definido pelo tamanho médio da região urinária nas imagens de treino.

3.3. Detecção da Calcificação

Para a detecção das calcificações foi utilizada a YOLOv5 especificamente do repositório *ultralytics*¹. Os modelos testados neste trabalho foram: nano, small, medium e large, respectivamente representados por YOLOv5n, YOLOv5s, YOLOv5m e YOLOv5l. A YOLOv5 consiste em utilizar três tipos de mapas de características de saída para detectar objetos de tamanhos diferentes e utiliza 8 mapas de características de saída de baixa resolução para detectar objetos pequenos. Os diferentes modelos da YOLOv5 apresentam variações na quantidade de camadas, complexidade, precisão média, velocidade de detecção e treinamento, permitindo, assim, uma avaliação para se determinar qual o melhor modelo para detectar as calcificações de maneira mais rápida e com uma porcentagem

¹<https://github.com/ultralytics/yolov5>

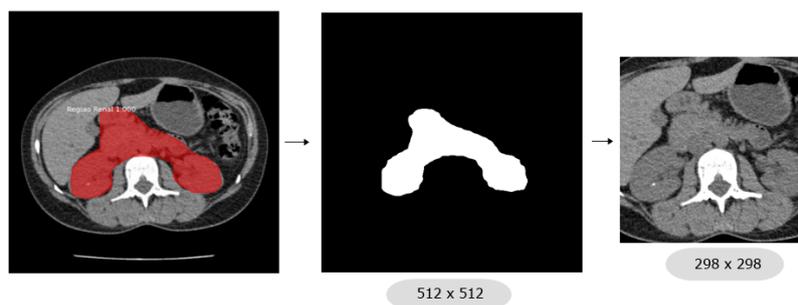


Figura 3. Fluxo da criação da janela 298×298 da segmentação da região renal. A imagem da esquerda representa a área da região de interesse (vermelho). A imagem central representa a máscara da região de interesse. A imagem da direita, temos uma janela (298×298) com o centroide da região renal.

de acerto maior [Sozzi et al. 2022].

A escolha da YOLOv5 se deu a partir da busca na literatura, pois com poucas amostras a rede se mostrou eficiente para a detecção eficiente de objetos. Além disso, a YOLOv5 mostrou-se eficiente em outras tarefas, inclusive na detecção de outras estruturas médicas como lesões mamárias [Baccouche et al. 2022], pâncreas [Davradou 2021] e tumores cerebrais [Montalbo 2020]. Com base no exposto, investigamos os modelos pré-treinados e com isso obtivemos resultados satisfatórios na detecção de calcificações mesmo com conjunto reduzido de amostras.

Para cada versão da YOLOv5, configuramos e avaliamos o parâmetro *imgsize*, que define o tamanho das imagens de entrada. Neste estudo, compararam-se os modelos YOLOv5 e os tamanhos de entrada 298×298 , 512×512 e 640×640 para a detecção automática de calcificações renais.

O desempenho da YOLOv5 é medido através da definição do valor do limite de confiança, este valor determina o comportamento da precisão. Conforme a análise, se o valor do limite de confiança for inferior a 0,5, a precisão será relativamente baixa, inferior a 80%; se o valor do limite de confiança definido for acima de 0,5, o *Mean Average Precision* (mAP) irá diminuir gradualmente [Yan et al. 2021]. Desta forma, o limite de confiança estabelecido foi de 0,5, que estabelece um equilíbrio entre a precisão e o mAP.

3.4. Avaliação dos resultados

Para avaliação dos resultados foram utilizadas as métricas frequentemente utilizadas na literatura, como *Intersection over Union* (IOU) para avaliar o desempenho da Mask R-CNN. Já com relação dos resultados da YOLOv5, foram utilizadas as métricas: mAP, Precisão e *Recall* [Padilla et al. 2020].

4. Resultados e discussão

Os resultados apresentados nesta seção foram obtidos a partir dos conjuntos de imagens segmentadas e não segmentadas. Na detecção e segmentação do sistema urinário, o modelo Mask-RCNN, foi treinado com taxa de aprendizado 0.0001, *batch size* de tamanho 4 e 5 épocas com 500 passos. A divisão do conjunto de dados das imagens de TC foi de 16 exames para treino e 4 exames para teste, totalizando 792 imagens para treino e 95 de teste, de tamanho 512×512 . Vale destacar que na divisão dos conjuntos de treino e teste,

os exames foram separados para que não ficassem regiões de um mesmo exame presente no conjunto de treino e teste simultaneamente. A segmentação na Mask-RCNN obteve IOU de 0,98 e obteve bons resultados em seus experimentos de detecção e segmentação do sistema urinário. Regiões como ossos, tumores e cristais que estavam fora da região renal foram removidas.

O treinamento da YOLOv5 foi realizado com as imagens segmentadas e não segmentadas. Nestes experimentos aplicamos a validação cruzada (*k-fold*) com o número de *k* igual a 5. O *dataset* utilizado é formado por 20 exames, totalizando 532 amostras com calcificação. Foram avaliados 4 versões da YOLOv5, utilizando os seguintes parâmetros: 200 épocas, *batch size* igual a 8, taxa de aprendizado 0.0001 e o otimizador Adam [Thuan 2021]. Além da variação das versões da YOLOv5, avaliamos também diferentes tamanhos de entrada da rede. Para as imagens não segmentadas, utilizamos o tamanho original de 512×512 e o tamanho 640×640 que corresponde ao tamanho padrão de treinamento da YOLOv5. Já as imagens segmentadas, utilizamos o tamanho 298×298 que foi o tamanho resultante após etapa de segmentação e 640×640 que corresponde ao tamanho padrão de treinamento da YOLOv5.

Os experimentos foram realizados em uma máquina com as seguintes configurações: processador Intel(R) Xeon(R) CPU E5-2683 v4 2.10GHz, 128 GB de memória RAM e GPU Tesla K80 com 12 GB de memória. Os resultados obtidos são apresentados nas Tabelas 2, 3, 4 e 5, foram calculadas as médias das 5 execuções para cada modelo apresentado e o desvio padrão.

A Tabela 2, contém os resultados dos experimentos com as imagens originais (não segmentadas) com tamanho de entrada 512×512 . Destacamos que com base na métrica mAP_05, observa-se que o modelo que se destacou foi a YOLOv5l. Este modelo por possui um número maior de camadas, é uma versão da rede mais larga, pode ter proporcionar um aprendizado mais eficiente em relação os demais modelos. Analisando a métrica de precisão, este modelo também obteve uma melhor resultado se comparados aos demais. Ainda com base na Tabela 2, os demais modelos apresentam resultados bem abaixo da YOLOv5l. Isso por ter acontecido devido o tamanho das imagens de 512×512 e as calcificações são bem pequenas, podendo assemelhar com outras estruturas, como regiões que contém ossos que pode confundir a rede na etapa de detecção.

Tabela 2. Comparação entre as variações do modelo YOLOv5 treinadas com 200 épocas usando as imagens originais (sem a segmentação da região renal), com tamanho de entrada 512×512 .

Yolo	mAP_0.5	Precisão	Recall
n	$0,3184 \pm 0,2025$	$0,4467 \pm 0,2127$	$0,3671 \pm 0,2076$
s	$0,3754 \pm 0,2884$	$0,4948 \pm 0,2864$	$0,4008 \pm 0,2631$
m	$0,3436 \pm 0,2365$	$0,4694 \pm 0,2234$	$0,3890 \pm 0,2228$
l	$0,3916 \pm 0,2624$	$0,5899 \pm 0,2335$	$0,3751 \pm 0,2311$

A Tabela 3, apresenta os resultados dos experimentos com as imagens originais (não segmentadas) com tamanho de entrada redimensionadas para 640×640 . Este processo de redimensionamento visa avaliar o desempenho dos modelos da YOLOv5 com o tamanho de entrada padrão, quando se refere as redes pré-treinadas. Observamos que o

modelo que obteve melhor resultado foi a YOLOv5l. Ressaltamos que esse processo de redimensionamento aumentou significativamente todas as métricas se comparamos os modelos YOLOv5l 512 \times . Destacamos ainda que ao redimensionar as imagens, as calcificações tendem a aumentar, que por sua vez facilita o processo de detecção das mesmas pela YOLO. Sendo assim, o treinamento com as imagens originais redimensionadas para 640 \times 640 requer uma rede com mais camadas profundas e mais épocas de treinamento.

Tabela 3. Comparação entre as variações do modelo YOLOv5 treinadas com 200 épocas usando as imagens originais (sem a segmentação da região renal), com tamanho de entrada 640 \times 640.

Yolo	mAP_0.5	Precisão	Recall
n	0,2936 \pm 0,2429	0,5518 \pm 0,1788	0,2926 \pm 0,2326
s	0,2961 \pm 0,2165	0,4320 \pm 0,1789	0,3351 \pm 0,1939
m	0,2453 \pm 0,1735	0,4226 \pm 0,1721	0,2729 \pm 0,1461
l	0,4055 \pm 0,3054	0,5594 \pm 0,2795	0,4115 \pm 0,2645

As Tabelas 4 e 5 apresentam os resultados obtidos utilizando as imagens segmentadas com a Mask-RCNN do sistema urinário. Observa-se que estes resultados melhoraram significativamente com relação às imagens não segmentadas. Isto ocorre porque ao segmentar a região renal nas imagens, é delimitado as regiões de interesse que contém somente as calcificações, e com isso ocorre a redução dos objetos da imagem que se assemelham as calcificações, tais como ossos, cistos e tumores que se localizam externamente no sistema urinário.

É relevante notar que, dos testes aplicados, o modelo YOLOv5n apresentado na Tabela 4, com tamanho de entrada 640 \times 640, se sobressaiu em comparação aos outros modelos, apresentando mAP_0,5 de 0,8950 e Precisão de 0,98705. Além de apresentar os melhores resultados, a YOLOv5n se sobressai pelo seu baixo custo computacional, uma vez que, em média, leva 3 a 4 segundos por época de treinamento, devido ao seu número reduzido de camadas profundas. O modelo YOLOv5n é capaz de detectar as regiões pequenas com mais eficiência, é menos sensíveis a *overfitting*, principalmente quando se utiliza base com poucas quantidades de amostras.

Tabela 4. Comparação entre as variações do modelo YOLOv5 treinadas com 200 épocas usando as imagens da região renal segmentadas, com tamanho de entrada 298 \times 298.

Yolo	mAP_0.5	Precisão	Recall
n	0,8422 \pm 0,0270	0,8102 \pm 0,0221	0,8125 \pm 0,0328
s	0,8525 \pm 0,0397	0,8392 \pm 0,0434	0,8419 \pm 0,0372
m	0,8635 \pm 0,0325	0,8562 \pm 0,0330	0,8450 \pm 0,0509
l	0,8802 \pm 0,0335	0,8660 \pm 0,0316	0,8616 \pm 0,0336

As Figuras 4 e 5, apresentam exemplos de sucesso e falha na detecção de calcificação. A Figura 4 apresenta um exemplo de caso de sucesso na detecção de calcificação para diferentes localizações e tamanho dos cristais em imagens do conjunto de teste. Neste exemplo temos duas calcificações marcadas pelo especialista na cor azul

Tabela 5. Comparação entre as variações do modelo YOLOv5 treinadas com 200 épocas usando as imagens da região renal segmentadas, com tamanho de entrada 640×640.

Yolo	mAP_0.5	Precisão	Recall
n	0,8950 ± 0,0476	0,8705 ± 0,0462	0,8580 ± 0,0449
s	0,8794 ± 0,0321	0,8749 ± 0,0409	0,8573 ± 0,0477
m	0,8727 ± 0,0483	0,8530 ± 0,0336	0,8654 ± 0,0463
l	0,8780 ± 0,0388	0,8681 ± 0,0513	0,8570 ± 0,0440

apresentada na Figura 4 (a) e a Figura 4 (b) apresentamos a detecção das calcificações. Observa-se que a rede conseguiu detectar corretamente a região que contém calcificação.

A Figura 5 mostra um exemplo de falha na detecção de calcificação. A Figura 5 (a) apresenta um exemplo de calcificação marcada pelo especialista e a Figura 5 (b) temos a detecção apresentada pela rede. Neste exemplo a rede falhou na detecção no seguinte cenário: detecção de ossos como calcificações. Diversos fatores podem influenciar na falha da detecção de calcificação, como o tamanho da calcificação, baixo contraste, tumores e/ou outros tipos de estruturas cristalizadas que surgem no fígado, pâncreas que são possíveis de visualizar nas fatias dos exames.

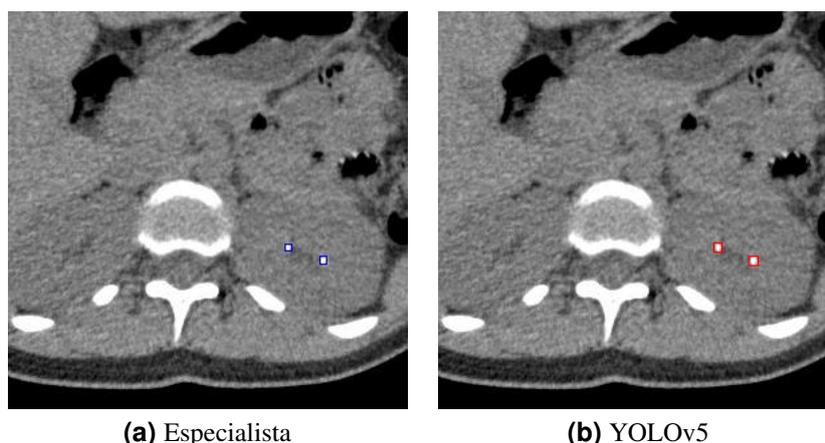


Figura 4. Exemplos de sucesso na detecção com as imagens segmentadas. A marcação de cor azul representa a máscara do especialista e a cor vermelha representa a detecção da rede.

A Tabela 6, apresenta um comparativo da metodologia proposta apresentados em negrito, com outros trabalhos encontrados na literatura. Muitos trabalhos utilizam diferentes técnicas para detecção e segmentação de calcificações. Alguns trabalhos consideram a detecção da borda dos rins, limiarização, técnicas de redução de ruído, já outros empregam a segmentação pela região do Abdômen. Vale destacar que os resultados apresentados são somente para efeito de comparação, pois as metodologias de avaliação e imagens utilizadas diferem de trabalho para trabalho.

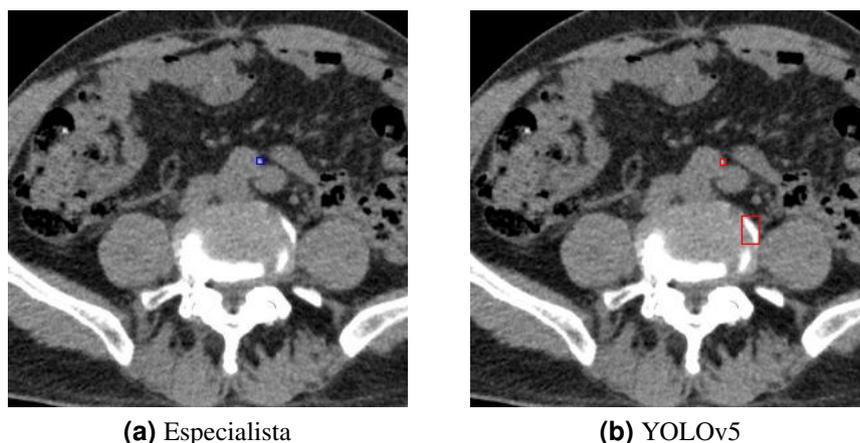


Figura 5. Exemplos de falha na detecção com as imagens segmentadas. A marcação de cor azul representa a máscara do especialista e a cor vermelha representa a detecção da rede.

Tabela 6. Comparação com o estado da arte

Trabalho	mAP_0.5	Precisão	Recall
[Viswanath and Gunasundari 2014]	-	0,9880	-
[Ebrahimi and Mariano 2015]	-	0,8461	-
[Thein et al. 2018]	-	-	0,9293
[Nithya et al. 2020]	-	0,9961	-
[Cui et al. 2021]	-	-	0,9590
[Yildirim et al. 2021]	-	0,9682	-
[Bayram et al. 2022]	0,8500	-	0,8820
Método proposto	0,8950	0,8705	0,8580

5. Conclusão e trabalhos futuros

Neste trabalho, apresentamos um método para detecção de calcificações em imagens de TC. Concluímos que para esta tarefa de detecção é necessário a utilização de técnicas de segmentação, pois regiões como ossos, tumores e cristais que estavam fora da região renal foram removidas, antes nas imagens sem segmentação essas regiões poderia ser confundidas com calcificação. De acordo como os modelos testados, notamos que a YOLOv5n apresentou um melhor desempenho no conjunto de imagens segmentadas e tamanho de entrada 640×640 . Mesmo que o modelos YOLOv5l 298×298 apresenta uma valor ligeiramente próximo a YOLOv5n 640×640 , mas a escolha da YOLOv5n se dá pelo fato de ser mais leve, por possuir menos camadas profundas, tornando assim seu desempenho nas etapas de treinamento e detecção mais rápido e eficiente.

Para trabalhos futuros, pretende-se investigar outras técnicas de *deep learning* para segmentação do sistema urinário. Utilizar técnicas de aumento de dados para ampliar o número de imagens no conjunto de treinamento dos modelos. Realizar uma etapa de busca e seleção de parâmetros da YOLOv5. Avaliar o desempenho dos modelos utilizando os exames de TC no formato DICOM com inteiros de 16 bits. Além disso, pretende-se realizar experimentos com outra base de calcificações renais.

Referências

- Baccouche, A., Garcia-Zapirain, B., Zheng, Y., and Elmaghraby, A. S. (2022). Early detection and classification of abnormality in prior mammograms using image-to-image translation and yolo techniques. *Computer Methods and Programs in Biomedicine*, 221:106884.
- Bayram, A. F., Gurkan, C., Budak, A., and KARATAŞ, H. (2022). A detection and prediction model based on deep learning assisted by explainable artificial intelligence for kidney diseases. *Avrupa Bilim ve Teknoloji Dergisi*, (40):67–74.
- Cui, Y., Sun, Z., Ma, S., Liu, W., Wang, X., Zhang, X., and Wang, X. (2021). 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.
- Davradou, A. (2021). Detection and segmentation of pancreas using morphological snakes and deep convolutional neural networks.
- Ebrahimi, S. and Mariano, V. Y. (2015). Image quality improvement in kidney stone detection on computed tomography images. *Journal of image and graphics*, 3(1):40.
- Girshick, R., Donahue, J., Darrell, T., and Malik, J. (2014). Rich feature hierarchies for accurate object detection and semantic segmentation. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 580–587.
- He, K., Gkioxari, G., Dollár, P., and Girshick, R. (2017). Mask r-cnn. In *Proceedings of the IEEE international conference on computer vision*, pages 2961–2969.
- Masood, A. et al. (2018). Computer-assisted decision support system in pulmonary cancer detection and stage classification on ct images. *Journal of Biomedical Informatics*, 79:117 – 128.
- Memarsadeghi, M., Heinz-Peer, G., Helbich, T. H., Schaefer-Prokop, C., Kramer, G., Scharitzer, M., and Prokop, M. (2005). Unenhanced multi-detector row ct in patients suspected of having urinary stone disease: effect of section width on diagnosis. *Radiology*, 235(2):530–536.
- Montalbo, F. J. P. (2020). A computer-aided diagnosis of brain tumors using a fine-tuned yolo-based model with transfer learning. *KSII Transactions on Internet and Information Systems (TIIS)*, 14(12):4816–4834.
- Nithya, A., Appathurai, A., Venkatadri, N., Ramji, D., and Palagan, C. A. (2020). Kidney disease detection and segmentation using artificial neural network and multi-kernel k-means clustering for ultrasound images. *Measurement*, 149:106952.
- Padilla, R., Netto, S. L., and Da Silva, E. A. (2020). A survey on performance metrics for object-detection algorithms. In *2020 international conference on systems, signals and image processing (IWSSIP)*, pages 237–242. IEEE.
- Parvathi, S. S. and Jonnadula, H. (2022). An efficient and optimal deep learning architecture using custom u-net and mask r-cnn models for kidney tumor semantic segmentation. *International Journal of Advanced Computer Science and Applications*.
- Pecoits-Filho, R. (2004). Diagnóstico de doença renal crônica: avaliação da função renal. *J Bras Nefrol*, 26(3):4–5.

- Prasetyo, E., Suciati, N., and Fatichah, C. (2020). A comparison of yolo and mask r-cnn for segmenting head and tail of fish. In *2020 4th International Conference on Informatics and Computational Sciences (ICICoS)*, pages 1–6. IEEE.
- Rangel, É. B., Gomes, S. A., and Heilberg, I. P. (2005). Litíase renal no pré e pós-transplante renal. *Brazilian Journal of Transplantation*, 8(4):440–445.
- Soares, E. F. and Aragão, G. S. (2013). Algoritmo de apoio para tratamento da litíase renal. In *Anais do Congresso de Matemática aplicada à computacional*, pages 303–305.
- Sozzi, M., Cantalamessa, S., Cogato, A., Kayad, A., and Marinello, F. (2022). Automatic bunch detection in white grape varieties using yolov3, yolov4, and yolov5 deep learning algorithms. *Agronomy*, 12(2):319.
- Thein, N., Hamamoto, K., Nugroho, H. A., and Adji, T. B. (2018). 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.
- Thuan, D. (2021). Evolution of yolo algorithm and yolov5: The state-of-the-art object detection algorithm.
- Tiago Ferolla Nunes, Denise M. Brunetta, C. M. L. P. C. B. P. J. S. R.-F. t. . I. r. a. (2010). *Biblioteca Escolar Em Revista*, 43(3):272–282. DOI: <https://doi.org/10.11606/issn.2176-7262.v43i3p272-282>.
- Viswanath, K. and Gunasundari, R. (2014). 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.
- Xu, B., Wang, W., Falzon, G., Kwan, P., Guo, L., Chen, G., Tait, A., and Schneider, D. (2020). Automated cattle counting using mask r-cnn in quadcopter vision system. *Computers and Electronics in Agriculture*, 171:105300.
- Yan, B., Fan, P., Lei, X., Liu, Z., and Yang, F. (2021). A real-time apple targets detection method for picking robot based on improved yolov5. *Remote Sensing*, 13(9):1619.
- Yildirim, K., Bozdag, P. G., Talo, M., Yildirim, O., Karabatak, M., and Acharya, U. R. (2021). Deep learning model for automated kidney stone detection using coronal ct images. *Computers in Biology and Medicine*, page 104569.
- Zhao, T., Yang, Y., Niu, H., Wang, D., and Chen, Y. (2018). Comparing u-net convolutional network with mask r-cnn in the performances of pomegranate tree canopy segmentation. In *Multispectral, hyperspectral, and ultraspectral remote sensing technology, techniques and applications VII*, volume 10780, pages 210–218. SPIE.