

# Segmentação da Região Pulmonar em Radiografias Pediátricas de Tórax

Afonso Ueslei da Fonseca<sup>1</sup>, Juliana Paula Felix<sup>1</sup>, Fabrizzio Soares<sup>1</sup>

<sup>1</sup>Instituto de Informática – Universidade Federal de Goiás (UFG)  
Alameda Palmeiras, Quadra D, Câmpus Samambaia – Goiânia – GO – Brasil

{afonsoueslei, julianafelix, fabrizzio}@ufg.br

**Abstract.** *In chest X-rays (CXR), the automatic identification of regions, structures, or objects that compose it can help the professional in the area to perform their reading and analysis more assertively, promoting the improvement and efficiency of the diagnosis. This work proposes a method to segment the lung fields in CXR. Based on digital image processing operations and the use of rules, the proposal is evaluated on a pediatric CXR images dataset. The results were satisfactory for the different classes of images analyzed, indicating that the proposed method can be practically used in pre-processing stages of more complex flows.*

**Resumo.** *Nas radiografias de tórax (RXT), a identificação automática de regiões, estruturas ou objetos que a compõem pode auxiliar o profissional da área a realizar sua leitura e análise de forma mais assertiva, promovendo a melhoria e eficiência do diagnóstico. Este trabalho propõe um método para segmentar os campos pulmonares em RXT. Com base em operações de processamento digital de imagens e uso de regras, a proposta é avaliada em um banco de dados de imagens RXT pediátricas. Os resultados satisfatórios para diferentes classes de imagens analisadas indicam que o método proposto pode ser utilizado de forma prática em etapas de pré-processamento de fluxos mais complexos.*

## 1. Introdução

Radiografias de Tórax (RXT) são cruciais na análise, rastreamento, acompanhamento e diagnóstico de várias doenças. A partir delas é possível realizar a avaliação de várias estruturas anatômicas da região torácica, como o arcabouço ósseo, partes moles, pulmões, mediastino, linhas ou bordas cardíacas, além de grandes vasos, apenas para citar algumas. Em sistemas de detecção e diagnóstico assistidos por computador (CADx), RXT são frequentemente usadas como entrada para auxiliar no diagnóstico de doenças como Tuberculose, Pneumonia, Cânceres e, mais recentemente, a COVID-19, entre outras.

Uma etapa comum em sistemas CADx que lidam com imagens RXT é a segmentação. Esta tarefa constitui-se do processo de divisão da imagem em partes, regiões ou estruturas que a compõem, e é sempre guiada pelo problema a ser resolvido. Assim, esta é uma etapa importante e necessária que compreende um primeiro e crítico componente para a leitura e análise das RXT. Além disso, a segmentação está associada à redução do processamento computacional, e à melhora da eficiência, acurácia e precisão de sistemas CADx, podendo ainda cobrir tarefas como detecção e localização de lesões, infecções e cânceres.

Vários sistemas CADx utilizam imagens RXT segmentadas, considerando apenas a região dos pulmões. Uma consequência deste processo é que certas regiões necessárias para análise de outras doenças detectáveis por meio de RXT acabam ficando de fora. Este é o caso da região do coração, necessária para o diagnóstico da cardiomegalia, ou das regiões das costelas, clavículas e coluna essenciais para identificar fraturas e padrões de rotação, por exemplo. Desse modo, a segmentação que engloba toda a região pulmonar representa uma importante tarefa com aplicações práticas.

A segmentação automatizada tem como vantagens oferecer um mecanismo que supera o tédio envolvido na segmentação manual de grandes conjuntos de dados, e permitir a reprodutibilidade, o que é difícil de ser alcançado com resultados definidos manualmente [Clarke et al. 1995]. No entanto, problemas significativos devem ser superados para atingir precisão por meios automáticos, e essa área de pesquisa permanece ativa [Chen et al. 2021, Hesamian et al. 2019, Zhou et al. 2018]. Além disso, técnicas computacionais disponíveis para segmentação de imagens médicas são específicas por aplicação, modalidade de imagem ou parte corporal analisada, inexistindo um método universal que alcance toda e qualquer imagem médica.

Consequentemente, o processo de segmentação não é trivial e constitui uma das tarefas mais difíceis no processamento digital de imagens, sendo determinante em procedimentos de análise computadorizada [Gonzalez and WOODS 2010]. Em imagens médicas e, mais especificamente, imagens radiológicas, a segmentação é ainda mais desafiadora devido a algumas características de RXT. Baixo contraste entre as regiões de interesse e outras texturas, variações de iluminação e condições de aquisição da imagens, são algumas dessas características [Taheri et al. 2021].

No sentido de contribuir nessa área de pesquisa, apresentamos neste trabalho um método automatizado para segmentação da região dos campos pulmonares em imagens RXT pediátricas. Nossa proposta baseia-se na definição de uma região de interesse (ROI)<sup>1</sup> correspondente aos limites externos da região da caixa torácica. Assim, toda região diferente a região torácica é descartada, prevenindo efeitos indesejáveis dessas regiões na análise por sistemas CADx. Na Figura 1, apresentamos alguns exemplos de regiões estranhas à região torácica.



**Figura 1. RXT pediátricas públicas com estruturas estranhas à região torácica.**

Este trabalho está organizado da seguinte forma. Na Seção 2, apresentamos alguns trabalhos relacionados. Na Seção 3, o método proposto é descrito. Os resultados são

<sup>1</sup>do inglês *region of interest* - ROI

apresentados e comentados na Seção 4. As considerações finais seguem na Seção 5.

## 2. Trabalhos relacionados

Recentemente, diversas pesquisas relacionadas à segmentação automatizada de imagens médicas com uso de aprendizagem profunda tem sido publicados. Os propósitos dos trabalhos encontrados são variados, estabelecendo alternativas consistentes para a segmentação de pulmões, de disco óptico, e veias [Taheri et al. 2021, Shi et al. 2021, Mahmood et al. 2020, Gu et al. 2019], por exemplo.

[Shi et al. 2021, Fan et al. 2020] abordaram a segmentação em imagens RXT no contexto da COVID-19. Os primeiros revisaram técnicas de IA para aquisição de dados, diagnóstico e segmentação, pontuando a importância da segmentação no auxílio ao diagnóstico e na quantificação de lesões, e o uso da rede *U-Net* [Ronneberger et al. 2015] como o principal modelo adotado. Os últimos, desenvolveram um modelo de rede neural chamada *Inf-Net* para identificar e segmentar regiões infectadas pelo vírus a partir de cortes de tomografia computadorizada de tórax.

[Teixeira et al. 2020] avaliaram o impacto que a segmentação dos pulmões em imagens RXT exerce no diagnóstico e explicação da COVID-19. Um poder maior de generalização dos modelos que usam segmentação em oposição aos que não usam foi apontado. A segmentação força os modelos a olharem para regiões que realmente importam, reduzindo vieses e aumentando a qualidade dos modelos de interpretação e explicação, como nos mapas de ativação. Os autores também realizaram a segmentação dos pulmões [Oh et al. 2020] para desenvolver um modelo robusto de detecção de COVID em um pequeno conjunto de imagens RXT.

Em [Gordienko et al. 2018], a segmentação dos pulmões foi usada para a análise de lesões e nódulos suspeitos de câncer em imagens RXT, e então combinada e comparada com a supressão de clavículas e sombras de costelas. Os autores concluíram pela importância dessas técnicas na redução de sobre-ajustes (*overfitting*) e vieses relacionados às regiões circundantes aos pulmões.

Outras pesquisas utilizaram métodos tradicionais como aqueles baseados em região, classificação, clusterização, corte gráfico e modelos ativos de forma, entre outros. Os resultados alcançados por esses métodos mostraram-se bastante úteis e como uma alternativa viável para muitos casos. A seguir, apresentamos alguns destes resultados encontrados na literatura.

[Li et al. 2016] apresentaram um método de segmentação de pulmões baseado em modelos estatísticos de forma e modelos de aparência. Para os modelos de forma, ‘multi-escala’ e ‘multi-passos-tamanho’ com diversos parâmetros de limitação foram usados. Já para o modelo de aparência, características múltiplas com diferentes pesos foram utilizados para descrever as diferentes partes do limite de campo do pulmão.

O professor Dr. Ginneken, da *Radboud University Nijmegen Medical Centre*, descreveu em sua tese [Van Ginneken 2001] várias técnicas de segmentação para análise de RXT por computador. Renomados pesquisadores como a Dra. Sema Candemir e o Dr. Sammer Antani também tem publicado vários trabalhos sobre a segmentação de pulmões em imagens RXT e o aprimoramento de sistemas CADx [Peng et al. 2020, Candemir and Antani 2019, Candemir et al. 2014, Jaeger et al. 2013, Xue et al. 2015].

[Hogeweg et al. 2012] segmentou clavículas por classificação de *pixel* e modelo de forma ativa (do inglês *Active Shape Model - ASM*) empregando programação dinâmica com uma função de custo otimizado. Em [Schalekamp et al. 2016], os autores avaliaram o efeito da supressão óssea [Hogeweg et al. 2013] no diagnóstico de anormalidades comuns em RXT. Já em [Patil and Udupi 2012], um algoritmo bastante simples para pré-processamento de imagens CT foi descrito. O algoritmo é composto de 2 fases: filtragem de média e operações morfológicas, utilizadas para aumentar o desempenho da segmentação de tumores.

O Dr. Iakovidis, professor e pesquisador na Universidade de Thessaly, na Grécia, propôs um modelo também baseado em ASM para a detecção das fronteiras de campos pulmonares em imagens RXT com presença de infecções pulmonares e adquiridas por aparelhos portáteis de RX [Iakovidis et al. 2009]. Posteriormente, esse modelo foi utilizado para criar um *framework* de reconhecimento de padrões, composto por um classificador hierárquico, para medir a extensão das infiltrações pulmonares em imagens RXT [Tsevas and Iakovidis 2011].

### 3. Materiais e métodos

Nossa proposta compõe-se como um método tradicional baseado em operações de processamento digital de imagens e uso de regras para segmentar campos pulmonares. Para isso, quatro pontos (esquerdo, direito, superior e inferior) são automaticamente identificados e utilizados para guiar a segmentação da região da caixa torácica. A Figura 2 exemplifica o método proposto com os pontos de referência encontrados automaticamente (Fig. 2a), e a segmentação resultante do processo (Fig. 2b).

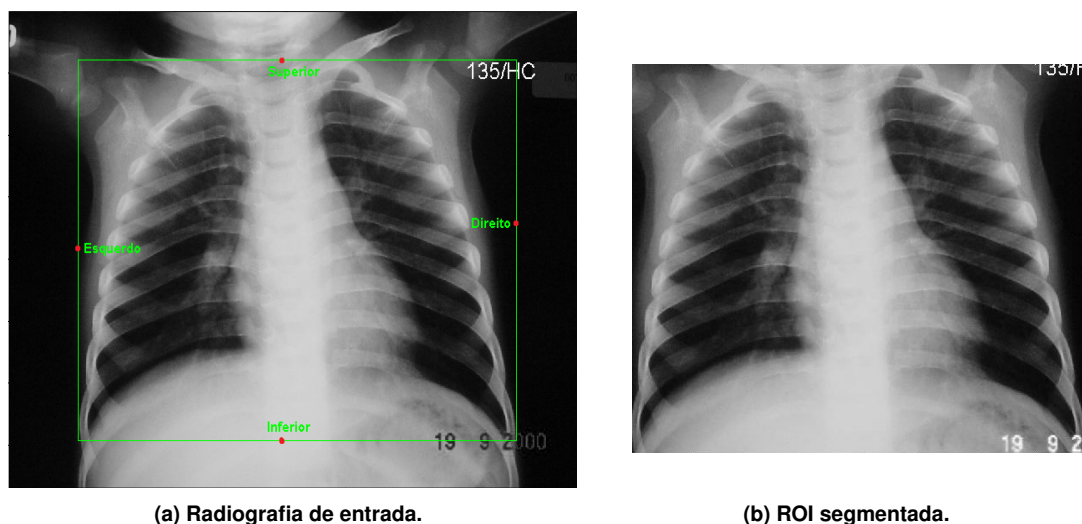


Figura 2. Definição dos pontos da ROI e imagem segmentada resultante.

As seções seguintes detalham a base de dados, a técnica utilizada para demarcar os pontos horizontais e verticais da região de interesse e, por fim, as métricas utilizadas para avaliar o método proposto.

#### 3.1. Base de dados

Para realização dos experimentos e avaliação da proposta, utilizamos um subconjunto composto por 150 imagens RXT pediátricas selecionadas de um banco de dados do Ins-

tituto de Patologia Tropical e Saúde Pública (IPTSP) da Universidade Federal de Goiás (UFG), descrito com mais detalhes em [Fonseca et al. 2016].

As imagens utilizadas foram selecionadas aleatoriamente e distribuídas igualmente em três classes, rotuladas como ‘Bacteriana’, ‘Normal’ e ‘Indeterminada’, indicando casos com diagnóstico confirmado de pneumonia bacteriana, casos normais ou saudáveis, e casos sem diagnóstico determinado, respectivamente. Todas as 150 imagens RXT foram manualmente marcadas em quatro pontos da ROI para serem utilizadas como referência e permitir a comparação com o método automático proposto. Nas subseções a seguir, descrevemos como nosso método define automaticamente cada um desses pontos.

### 3.2. Marcação dos pontos esquerdo e direito

A marcação dos pontos esquerdo e direito na RXT é alcançada pela execução dos seguintes passos: a) Transformada *top-hat*, b) Binarização, c) Seleção dos dois maiores segmentos e d) Definição dos limites esquerdo e direito.

a) **Transformada *top-hat***: definida como

$$T_{hat}(f) = f - (f \circ b), \quad (1)$$

onde  $f$  é uma imagem em níveis de cinza e  $(f \circ b)$  é operação de abertura sobre ela.

Uma das principais aplicações dessa transformada é a remoção de objetos de uma imagem usando um elemento estruturante na operação de abertura. A operação de diferença produz então uma imagem em que apenas os componentes removidos permanecem. Essa operação é usada para objetos claros sobre um fundo escuro, tendo importante uso para correção de efeitos de iluminação não-uniforme.

Para o esquema proposto, utilizou-se a transformada *top-hat* com um elemento estruturante na forma de disco com raio igual a 32, definido empiricamente. O objetivo é realçar regiões de maior densidade da imagem, aquelas correspondentes às estruturas ósseas. Na Figura 3 é possível observar uma RXT da base de dados utilizada (Fig. 3a) e o resultado após a aplicação da transformada *top-hat* (Fig. 3b).




Figura 3. Definição do pontos esquerdo e direito. a) Imagem RXT, b) *Top-hat*, c) Binarização e d) Maiores segmentos.

b) **Binarização** : sobre a imagem resultante da transformada *top-hat* ( $T_{hat}$ ), uma operação de binarização é realizada seguindo a seguinte regra:

$$I_{bin}(x, y) = \begin{cases} 0 & \text{se } T_{hat}(x, y) < \mu(T_{hat}) * 1.25 \\ 1 & \text{se } T_{hat}(x, y) \geq \mu(T_{hat}) * 1.25 \end{cases} \quad (2)$$

onde  $\mu(T_{hat})$  é a intensidade média da imagem  $T_{hat}$ ,  $x$  e  $y$  são as coordenadas dos *pixels* da imagem. O resultado  $I_{bin}(x, y)$  é uma imagem com as estruturas mais densas destacadas em branco e o fundo em preto como mostrado na Figura 3c.

**c) Seleção dos dois maiores segmentos:** para eliminar pequenos segmentos, como aqueles decorrentes de artefatos, filtramos os dois maiores segmentos da imagem binária ( $I_{bin}$ ). Com isso, mantém-se o conjunto de costelas esquerdas e direitas na RXT.

**d) Definição dos pontos esquerdo e direito:** se dá pela localização do primeiro *pixel* mais à esquerda e do último *pixel* mais à direita da imagem binária resultantes do passo c). O resultado é exemplificado na Figura 3d.

### 3.3. Marcação dos pontos superior e inferior

Definidos os dois primeiros pontos, as regiões da imagem localizadas antes do ponto esquerdo e depois do ponto direito são descartadas (veja Figura 4a). Seguimos, então, para a definição dos pontos superior e inferior, alcançados pela realização da seguinte sequência de operações: a) Imagem negativo da limiarização por *Otsu*, b) Definição do vale, c) Perfil soma das linhas da imagem e d) Definição dos pontos superior e inferior.

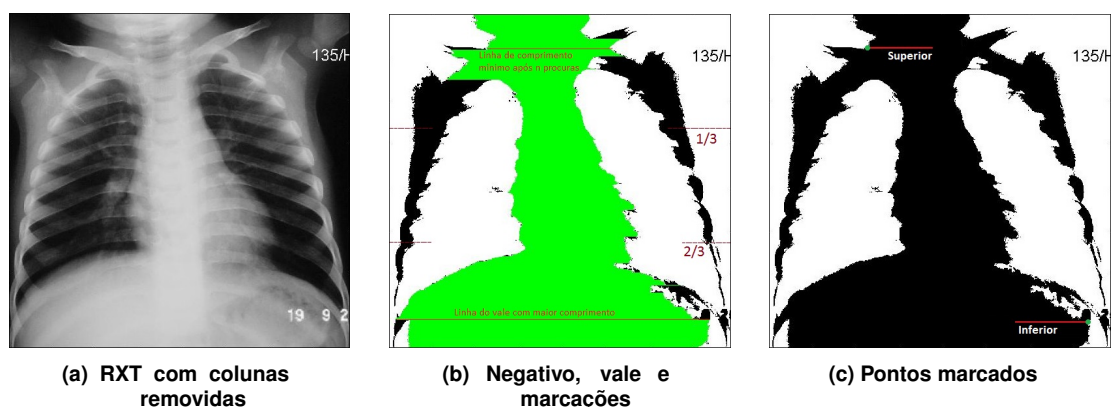


Figura 4. Definição dos limites superior e inferior.

**a) Negativo da limiarização por *Otsu*:** a limiarização por *Otsu* é método que determina um limiar ótimo para separar uma imagem em duas partes, correspondentes à 'frente' e ao 'fundo' da imagem. Para isso, as regiões mais claras da imagem são setadas em 1 ('frente'), e as regiões mais escuras são setadas em 0 ('fundo'). O *negativo* é o processo que inverte esses valores na imagem.

**b) Definição do vale:** o vale corresponde à região central da RXT destacada em verde na Figura 4b. Essa região é demarcada por um processo que se inicia nas colunas centrais da RXT (aproximação do mediastino) e caminha-se da esquerda à direita até encontrar um ponto da imagem com valor 1 (*pixel* branco). Definido o vale, a imagem é dividida em três faixas horizontais de mesmo tamanho. A partir daí, encontra-se a localização de uma linha de menor comprimento na faixa superior da imagem, e a de maior comprimento na faixa inferior.

**c) Perfil soma das linhas da imagem:** o perfil *soma* é apenas uma contagem da quantidade de *pixels* brancos em cada uma das linhas da imagem. Este valor serve para avaliar o percentual da imagem que foi considerada como 'fundo' pelo processo de

limiarização (passo a)). Diferentemente da análise das linhas do vale, o perfil *soma* das linhas da imagem permite recuperar informação de regiões descontínuas de fundo, o que não é possível com as linhas do vale.

**d) Definição dos pontos superior e inferior:** a definição destes pontos é realizada avaliando-se o comprimento das linhas do vale e os valores do perfil *soma*, obedecendo-se às seguintes restrições:

1. o ponto superior deve ser localizado na faixa superior da imagem, e o ponto inferior na faixa inferior da imagem.
2. margens externas de segurança de até 64 *pixels* devem ser acrescentadas em relação aos pontos superior e inferior encontrados.
3. a razão entre a altura e a largura da imagem não deve ser superior a 85%. Segundo [Candemir et al. 2015], o contorno cardíaco em imagens RXT pediátricas é até 60% maior que o diâmetro torácico horizontal, o que resulta numa ROI ligeiramente retangular. Isso também foi verificado em nossas marcações manuais, que tiveram altura variando entre 41,2% a 84,8% da largura.

O ponto superior é definido procurando, a partir da linha 1, a primeira ocorrência com comprimento  $\geq 90\%$  do maior comprimento de linha do vale. Se não existir ou se a linha estiver num ponto  $> 20\%$  da altura da imagem, então é procurado no perfil *soma* a primeira ocorrência cujo valor seja  $\geq 80\%$  da largura da imagem. Se ainda assim não for encontrado nenhuma ocorrência, então o ponto superior considerado será a primeira da linha do vale com o comprimento mínimo. Para o ponto inferior, procura-se na faixa inferior à primeira ocorrência de linha com comprimento máximo dentre as linhas do vale.

Definido esses pontos, as regiões acima do ponto superior e abaixo do ponto inferior são removidas. Caso a 3ª restrição não tenha sido atendida, novas buscas são realizadas seguindo os mesmos critérios até que essa restrição seja atendida. As imagens na Figura 4 mostram as linhas encontradas no vale e os limites da 1ª restrição (Fig. 4b), e também os pontos superior e inferior que delimitam a ROI nesta imagem RXT (Fig. 4c).

### 3.4. Métricas de Avaliação

Na avaliação do método proposto, utilizou-se as 150 imagens RXT mencionadas na Seção 3.1. Para cada imagem, os quatro pontos da ROI definidos manualmente foram utilizados como referência.

Em seguida, para medir a precisão do método proposto, utilizamos os coeficientes de similaridade DICE (DSC, do inglês *Dice similarity coefficient*) e Jaccard (IoU, do inglês *Intersection over Union*), definidos pelas Equações 3 e 4.

$$DSC(A, B) = 2 * \frac{|\cap(A, B)|}{(|A| + |B|)}, \quad (3)$$


$$IoU(A, B) = \frac{|\cap(A, B)|}{|\cup(A, B)|}, \quad (4)$$

onde A e B representam, respectivamente, a região desejada da caixa torácica (verdadeira positiva) e a região a ser descartada, externa à caixa torácica (verdadeira negativa). Adi-



cionalmente, propomos também uma escala de precisão baseada na distância dos pontos encontrados pelo método proposto em relação aos pontos de referência coletados manualmente. Na definição dessa escala, a altura média das costelas foi considerada, chegando a um valor de 32 *pixels*. Esse valor é usado por ser uma tolerância aceitável na definição da ROI, já que os ápices pulmonares se iniciam abaixo da primeira costela.

A precisão foi, então, tabelada em seis níveis, apresentados na Figura 5. Do total, três deles são positivos – representando pontos detectados além dos limites de referência (correspondente a falsos positivos) – e três são níveis negativos – representando pontos aquém dos limites de referência (correspondente a falsos negativos).



**Figura 5. Níveis de precisão adotados para avaliação da ROI.**

## 4. Resultados

Na Tabela 1, apresentamos os valores obtidos de DSC, *Jaccard* (IoU), e também a acurácia do método em nossa escala de precisão para o nível 0 (ACC-0) e nível 1 (ACC-1). Os resultados apresentados correspondem à análise de todos os quatro pontos encontrados, para cada uma das três classes das imagens RXT.

**Tabela 1. Resultados do processo de definição e segmentação da caixa torácica.**

Classe das imagens	Métricas calculadas			
	DSC	IoU	ACC-0	ACC-1
Normal	0.958	0.922	0.790	0.970
Bacteriana	0.956	0.916	0.820	0.935
Indeterminada	0.964	0.931	0.840	0.985
<b>Total</b>	<b>0.959</b>	<b>0.923</b>	<b>0.817</b>	<b>0.963</b>

Na Figura 6, os resultados em números absolutos dos quatro pontos detectados (Esquerdo, Direito, Superior e Inferior) são apresentados para as 3 classes: normais (Fig. 6a), indeterminadas (Fig. 6c) e bacterianas (Fig. 6b). Uma comparação da ROI utilizada como referência (linhas verdes) e a detectada pelo método proposto (linhas vermelhas) é apresentada na Figura 7, enquanto na Figura 8 são mostrados os piores casos.

### 4.1. Discussão

Observando os valores das métricas na Tabela 1, podemos deduzir não haver diferenças significativas entre classes, embora a classe ‘Bacteriana’ apresente valor fora do padrão na métrica ACC-1. Os valores mais baixos de ACC-0 são explicados por corresponderem à sobreposição ‘perfeita’ entre a referência e a predição. Os valores de DSC e ACC-1 são os mais relevantes, visto que tendem a medir algo mais próximo do desempenho médio, enquanto a IoU penaliza em maior grau os erros gerados.



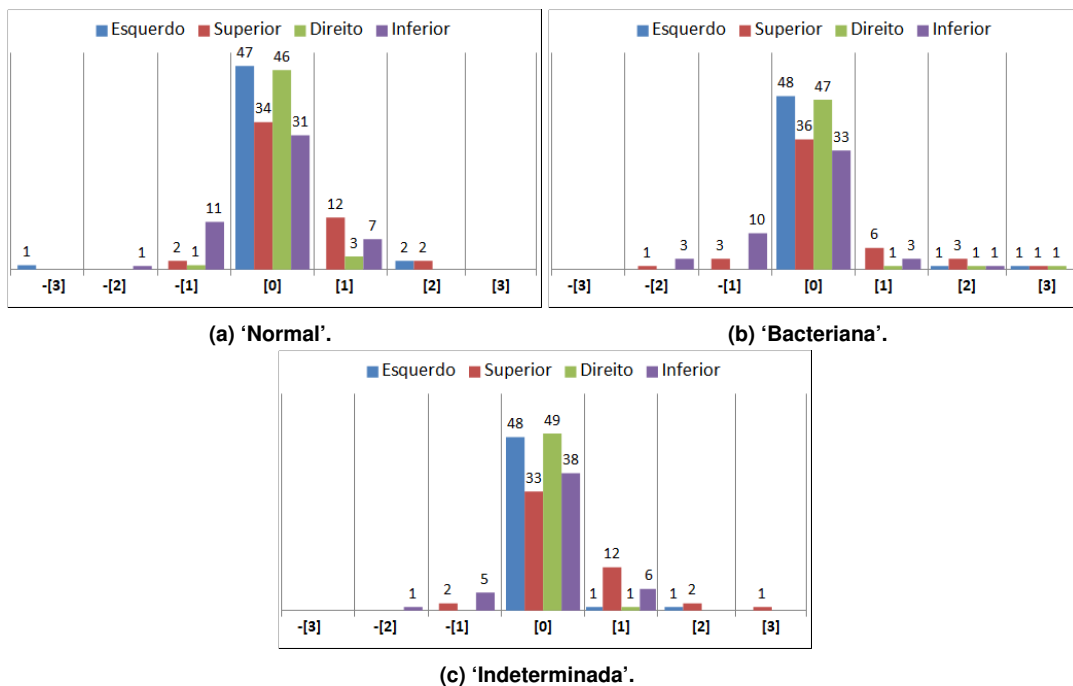


Figura 6. Pontos detectados em cada classe analisada.


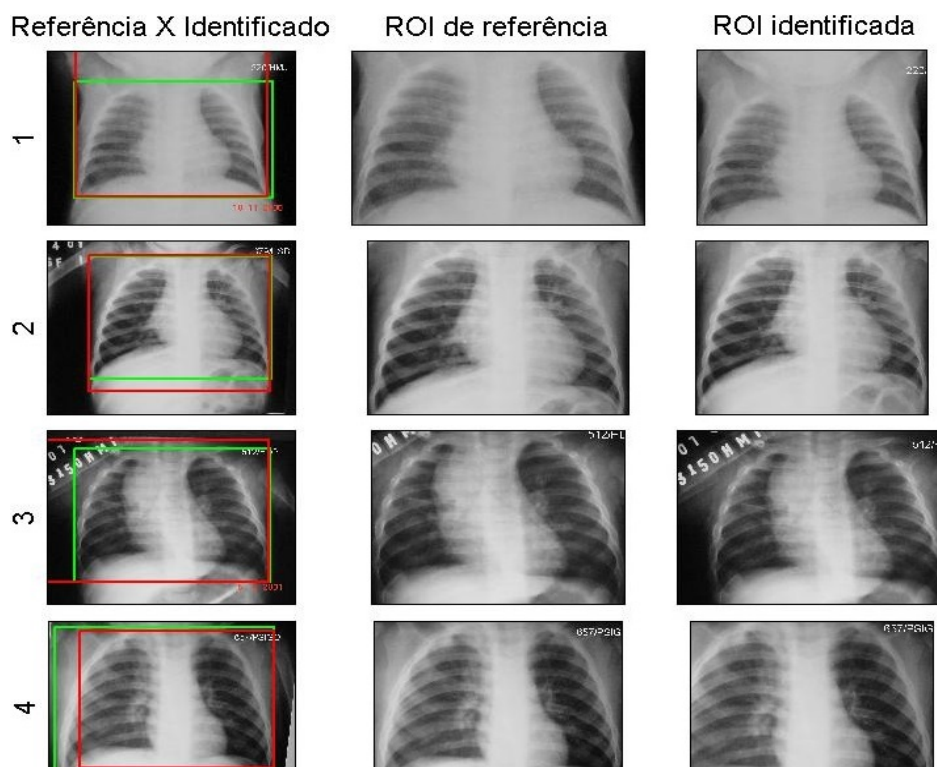


Figura 7. ROI's definidas em imagens RXT das 3 classes, sendo (1) bacteriana, (2) normal, (3) indeterminada.

Pelos gráficos dispostos na Figura 6, é possível perceber que a definição dos limites esquerdo e direito são melhor resolvidos (precisão média de 95% para o nível 0) em comparação aos pontos superior e inferior (precisão média de 68,3% para o nível 0), apontando uma dificuldade do método em identificar esses últimos. Essa dificuldade pode



**Figura 8. Piores ROI's definidas em imagens RXT das 3 classes, sendo (1-2) bacteriana, (3) normal, (4) indeterminada.**

ser explicada pela baixa qualidade das imagens (baixa resolução e contraste) que, por vezes, impossibilita a identificação dos ápices pulmonares (que define o ponto superior) e dos seios costofrênicos (que define o ponto inferior).

O desempenho inferior nas imagens da classe 'Bacteriana' é esperado e justificável, visto que as imagens dessa classe apresentam infiltrações, impactando tanto a definição de bordas, como a limiarização. É nessa classe onde o método apresenta a maior quantidade de pontos detectados nos níveis 2 e 3.

Outra importante observação é o fato de apenas um ponto (esquerdo) ter sido detectado no nível menos três (-3), vide imagem da linha 4 da Figura 8. Assim, a técnica apresenta uma alta sensibilidade, com pouca perda de ROI desejável, o que também pode ser conferido nos resultados expostos na Figura 7.

Finalmente, destaca-se a simplicidade da técnica desenvolvida, o seu baixo tempo de processamento (0,85 segundos) e a redução média do tamanho das imagens, não mencionado anteriormente, mas que alcançou 26,75%, habilitando assim a técnica para uso em sistemas CADx, sem grandes impactos.

## 5. Conclusões

Nesse artigo, apresentamos uma estratégia para segmentar regiões de interesse (ROI) em imagens de raio-X do tórax. A abordagem proposta foi testada e avaliada sobre um conjunto de dados de imagens RXT pediátricas de nossa instituição e os resultados foram apresentados utilizando métricas de avaliação apropriadas. A solução proposta trata-se de uma abordagem de bom desempenho, fácil implementação e baixa complexidade compu-

tacional e que não requer etapas de treinamento, o que a habilita a ser utilizada em etapas de pré-processamento em fluxos mais complexos.

## Referências

- Candemir, S. and Antani, S. (2019). A review on lung boundary detection in chest x-rays. *International journal of computer assisted radiology and surgery*, 14(4):563–576.
- Candemir, S., Antani, S., et al. (2015). Lung boundary detection in pediatric chest x-rays. In *Proc. SPIE, Medical Imaging 2015: PACS and Imaging Informatics: Next Generation and Innovations*, volume 9418, pages 94180Q–94180Q–6.
- Candemir, S., Jaeger, S., et al. (2014). Lung segmentation in chest radiographs using anatomical atlases with nonrigid registration. *IEEE Transactions on Medical Imaging*, 33(2):577–590.
- Chen, J., Lu, Y., Yu, Q., et al. (2021). Transunet: Transformers make strong encoders for medical image segmentation. *arXiv preprint arXiv:2102.04306*.
- Clarke, L., Velthuizen, R., Camacho, M., et al. (1995). MRI segmentation: methods and applications. *Magnetic resonance imaging*, 13(3):343–368.
- Fan, D.-P., Zhou, T., Ji, G.-P., Zhou, Y., et al. (2020). Inf-net: Automatic covid-19 lung infection segmentation from ct images. *IEEE Transactions on Medical Imaging*, 39(8):2626–2637.
- Fonseca, A. U., Oliveira, L. L. G., and Soares, F. A. A. M. N. (2016). Detecção de artefatos estranhos em radiografias de tórax. In *XV CBIS- Congresso Brasileiro de Informática em Saúde*, pages 721–730, Goiânia, Brasil.
- Gonzalez, R. C. and WOODS, R. E. (2010). *Processamento digital de imagens*. Pearson Prentice Hall, São Paulo, 3 edition.
- Gordienko, Y., Gang, P., Hui, J., Zeng, W., et al. (2018). Deep learning with lung segmentation and bone shadow exclusion techniques for chest x-ray analysis of lung cancer. In *International Conference on Computer Science, Engineering and Education Applications*, pages 638–647. Springer.
- Gu, Z., Cheng, J., Fu, H., et al. (2019). Ce-net: Context encoder network for 2d medical image segmentation. *IEEE Transactions on Medical Imaging*, 38(10):2281–2292.
- Hesamian, M. H., Jia, W., He, X., and Kennedy, P. (2019). Deep learning techniques for medical image segmentation: achievements and challenges. *Journal of digital imaging*, 32(4):582–596.
- Hogeweg, L., Sánchez, C. I., de Jong, P. A., et al. (2012). Clavicle segmentation in chest radiographs. *Medical Image Analysis*, 16(8):1490–1502.
- Hogeweg, L., Sanchez, C. I., and Van Ginneken, B. (2013). Suppression of translucent elongated structures: Applications in chest radiography. *IEEE Transactions on Medical Imaging*, 32(11):2099–2113.
- Iakovidis, D. K., Savelonas, M. A., and Papamichalis, G. (2009). Robust model-based detection of the lung field boundaries in portable chest radiographs supported by selective thresholding. *Measurement Science and Technology*, 20(10):104019.

- Jaeger, S., Karargyris, A., Candemir, S., Siegelman, J., et al. (2013). Automatic screening for tuberculosis in chest radiographs: a survey. *Quantitative imaging in medicine and surgery*, 3(2):89–99.
- Li, X., Luo, S., Hu, Q., Li, J., Wang, D., and Chiong, F. (2016). Automatic lung field segmentation in x-ray radiographs using statistical shape and appearance models. *Journal of Medical Imaging and Health Informatics*, 6(2):338–348.
- Mahmood, F., Borders, D., Chen, R. J., Mckay, G. N., et al. (2020). Deep adversarial training for multi-organ nuclei segmentation in histopathology images. *IEEE Transactions on Medical Imaging*, 39(11):3257–3267.
- Oh, Y., Park, S., and Ye, J. C. (2020). Deep learning covid-19 features on cxr using limited training data sets. *IEEE transactions on medical imaging*, 39(8):2688–2700.
- Patil, S. and Udupi, D. V. (2012). Preprocessing to be considered for mr and ct images containing tumors. *IOSR Journal Electrical and Electronics Engineering*, 1(4):54–57.
- Peng, T., Xu, T. C., Wang, Y., Zhou, H., et al. (2020). Hybrid automatic lung segmentation on chest ct scans. *IEEE Access*, 8:73293–73306.
- Ronneberger, O., Fischer, P., and Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. In *International Conference on Medical image computing and computer-assisted intervention*, pages 234–241. Springer.
- Schalekamp, S., Karssemeijer, N., Cats, A. M., De Hoop, B., et al. (2016). The effect of supplementary bone-suppressed chest radiographs on the assessment of a variety of common pulmonary abnormalities: Results of an observer study. *Journal of thoracic imaging*, 31(2):119–125.
- Shi, F., Wang, J., Shi, J., Wu, Z., et al. (2021). Review of artificial intelligence techniques in imaging data acquisition, segmentation, and diagnosis for covid-19. *IEEE Reviews in Biomedical Engineering*, 14:4–15.
- Taheri, M., Rastgarpour, M., and Koochari, A. (2021). A novel method for medical image segmentation based on convolutional neural networks with sgd optimization. *Journal of Electrical and Computer Engineering Innovations (JECEI)*, 9(1):37–46.
- Teixeira, L. O., Pereira, R. M., Bertolini, D., et al. (2020). Impact of lung segmentation on the diagnosis and explanation of covid-19 in chest x-ray images. *arXiv preprint arXiv:2009.09780*.
- Tsevas, S. and Iakovidis, D. K. (2011). Measuring the relative extent of pulmonary infiltrates by hierarchical classification of patient-specific image features. *Measurement Science and Technology*, 22(11):114017.
- Van Ginneken, B. (2001). *Computer-aided diagnosis in chest radiography*. PhD thesis, University Medical Center Utrecht.
- Xue, Z., Candemir, S., Antani, S., Long, L. R., Jaeger, S., Demner-Fushman, D., and Thoma, G. R. (2015). Foreign object detection in chest x-rays. In *Bioinformatics and Biomedicine (BIBM), 2015 IEEE International Conference on*, pages 956–961. IEEE.
- Zhou, Z., Siddiquee, M. M. R., Tajbakhsh, N., and Liang, J. (2018). Unet++: A nested u-net architecture for medical image segmentation. In *Deep learning in medical image analysis and multimodal learning for clinical decision support*, pages 3–11. Springer.