

UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA ELÉTRICA

LUIZA AOKI ALBERTO

Estudo de técnicas de segmentação de imagens baseadas em contorno ativo
aplicadas em tomografia computadorizada de pulmão

Uberlândia
2022

LUIZA AOKI ALBERTO

Estudo de técnicas de segmentação de imagens baseadas em contorno ativo
aplicadas em tomografia computadorizada de pulmão

Trabalho de Conclusão de Curso
apresentado à Faculdade de Engenharia
Elétrica da Universidade Federal de
Uberlândia como requisito parcial para
obtenção do título de bacharel em
Engenharia Biomédica.

Área de concentração: Engenharia
Biomédica

Orientador: Professora Dra. Ana Claudia
Patrocínio

Uberlândia

2022

LUIZA AOKI ALBERTO

Estudo de técnicas de segmentação de imagens baseadas em contorno ativo
aplicadas em tomografia computadorizada de pulmão

Trabalho de Conclusão de Curso
apresentado à Faculdade de Engenharia
Elétrica da Universidade Federal de
Uberlândia como requisito parcial para
obtenção do título de bacharel em
Engenharia Biomédica

Área de concentração: Engenharia
Biomédica

Uberlândia, 19 de agosto de 2022.

Banca Examinadora:

Ana Claudia Patrocínio

Márcia Simbara

Pedro Carneiro

Dedico este trabalho aos meus pais, Jane e Ari,
por toda uma vida de estímulo, carinho e
compreensão

AGRADECIMENTOS

À minha orientadora, Dra. Ana Claudia Patrocínio, por ter aceitado o convite de orientação, pelo auxílio dado durante este trabalho, respondendo e me explicando repetidas vezes tudo que não entendia, e por ter incentivado meu interesse na área de processamento de imagens de imagens médicas.

À minha família por todo apoio, motivação e carinho que sempre me deram durante toda a minha vida.

Aos meus pais, Jane e Ari, por aguentarem meus surtos e estresses, por me ajudarem a pensar e discutir temas vistos em aulas, por me ajudarem a revisar textos, por me apoiarem e motivarem em tudo que eu faço e por todo amor e carinho que sempre me deram durante toda minha vida.

A todos os amigos que fiz durante a graduação, por terem sido a minha família de Uberlândia. Com toda certeza não chegaria ao final da graduação sem o apoio e incentivo dessas pessoas.

À Carolina Beatriz Pereira da Silva, que aguenta o meu lado bom e ruim desde 2017, por todos os conselhos, por todas as fofocas que me distraíam, por todas as ajudas nos trabalhos, pelas revisões de texto, e pela companhia e suporte durante todos esses anos. Meu diploma também terá seu nome subentendido, pois não graduaria sem seu apoio.

Aos professores, que passaram pela minha graduação, por todas as dúvidas esclarecidas, por toda paciência, pela compreensão e por todos os ensinamentos que me fizeram chegar tão longe.

À professora Dra. Gabriela Lima Menegaz, por me permitir, apoiar e incentivar a adentrar no mundo da pesquisa, onde cresci e desenvolvi habilidades essenciais para a minha vida profissional.

A todos que participaram, direta ou indiretamente do desenvolvimento deste trabalho de pesquisa, enriquecendo o meu processo de aprendizado.

Muito obrigada!

RESUMO

No ranking global de principais causas de morte, estão diversas doenças pulmonares, como doença pulmonar obstrutiva crônica; infecções do trato respiratório inferior; e câncer de traqueia, brônquios e pulmão. Ainda, pode-se incluir nesse ranking a COVID-19. Assim, o diagnóstico precoce é fundamental para reduzir a mortalidade dessas doenças. A segmentação das lesões pulmonares é uma forma de auxiliar o diagnóstico que permite a melhor visualização da região de interesse pelo radiologista e a avaliação da progressão da doença. Dessa forma, o presente trabalho avalia dois algoritmos de segmentação baseados em contorno ativo, realizando técnicas de pré-processamento e de segmentação para extração dos pulmões e das lesões pulmonares de imagens tomográficas, juntamente com o desenvolvimento de uma interface MATLAB para seleção dos processamentos. A base de dados utilizada para os testes é composta pela seleção das fatias tomográficas de pulmão de exames presentes no repositório do Hospital São Lucas da Pontifícia Universidade Católica do Rio Grande do Sul (HSL-PUCRS) contendo imagens tomográficas de pulmão com diferentes patologias. O processamento foi dividido em diversas abordagens de pré-processamento e de segmentação, avaliando-se visualmente a detecção e segmentação das lesões pulmonares com ou sem a suavização de ruídos por meio de filtros; com ou sem o alargamento de contraste; e utilizando-se as técnicas de segmentação de contornos ativos pela função integrada ao MATLAB, *activecontour()* (MATLAB ACM), que realiza a técnica de contornos ativos por *level-set sparse field*, e com o uso da técnica *online region ORACM*, desenvolvida por Talu (2013). De maneira geral, a técnica *Online Region Active Contour Model* apresentou um melhor funcionamento do que a função incorporada ao MATLAB *activecontour()*, conseguindo detectar mais lesões e obter menos erros de extração. Apesar disso, esse método não conseguiu detectar todas as lesões presentes na imagem. Além disso, após a comparação de diferentes pré-processamentos, observou-se que os dois métodos possuíam mais facilidade para detectar as lesões sem a aplicação de filtros de suavização e com a realização do alargamento de contraste. Com relação à área de lesões detectadas pelos dois métodos, esta foi similar na maioria das fatias testadas, contudo, houve fatias que apresentaram erros de detecção. Portanto, é necessário expandir a análise, avaliando outra estratégia para extração da área pulmonar; outras métricas de análise e de segmentação; assim como, outras técnicas de pré-

processamento. Com relação à interface, ela permitiu facilitar a interação com os algoritmos de segmentação e comparação, além de tornar o código compartilhável. Contudo, ela precisa passar por otimizações.

Palavras-chave: segmentação de pulmão; contornos ativos; tomografia de pulmão; *online region active contour*; *level-set sparse field*; interface MATLAB.

ABSTRACT

In the global rank of leading causes of death are several lung diseases, such as chronic obstructive pulmonary disease; lower respiratory tract infections; and cancer of the trachea, bronchi, and lung. COVID-19 can also be included in this ranking. Thus, early diagnosis is essential to reduce the mortality of these diseases. The segmentation of lung lesions is a way to support the diagnosis that allows the radiologist to better visualize the region of interest and evaluate the progression of the disease. Thus, the present work evaluates two segmentation algorithms based on active contour, performing pre-processing and segmentation techniques for extraction of the lungs and lung lesions from CT images, along with the development of a MATLAB interface for processing selection. The database used for the tests is composed of the selection of lung tomographic slices of exams present in the repository of the Hospital São Lucas of the Pontifical Catholic University of Rio Grande do Sul (HSL-PUCRS) containing tomographic images of lungs with different pathologies. The processing was divided into several pre-processing and segmentation approaches, visually evaluating the detection and segmentation of lung lesions with or without noise smoothing by filters; with or without contrast stretching; and using the active contour segmentation techniques by the MATLAB integrated function, `activecontour()` (MATLAB ACM), which performs the active contour technique by level-set sparse field, and with the use of the online region ORACM technique, developed by Talu (2013). Overall, the Online Region Active Contour Model technique performed more effectively than the built-in MATLAB function `activecontour()`, detecting more lesions, achieving fewer extraction errors, and delineating the lesions' shape. Nevertheless, this method could not detect all the lesions present in the image. Furthermore, after comparing different preprocessing, it was observed that the two methods were able to detect the lesions more easily without applying smoothing filters and performing contrast stretching. The area of lesions detected by the two methods was similar in most slices tested, however, there were slices that presented detection errors. Therefore, it is necessary to expand the analysis by evaluating another strategy for extracting the lung area; other analysis and segmentation metrics; as well as other pre-processing techniques. Regarding the interface, it allowed easy interaction with the segmentation and comparison algorithms, also making the code shareable. However, it needs to undergo further optimizations.

Keywords: lung segmentation; active contours; lung tomography; online region active contour; level-set sparse field; *MATLAB interface*.

LISTA DE ILUSTRAÇÕES

Figura 1 - Esquema do processo de aquisição e reconstrução da imagem tomográfica	19
Figura 2 - Representação do funcionamento dos métodos de contornos ativos.	23
Figura 3 – Ilustração da função de ajuste de nível ϕ_x	28
Figura 4 - Esquema exemplo de aplicação de filtro de média 3x3	32
Figura 5 - Exemplo de alargamento de contraste.....	34
Figura 6 - Histogramas das imagens da Figura 5.....	35
Figura 7 – Representação gráfica da função de transformação para o alargamento de contraste por pedaços.....	36
Figura 8 - Representação gráfica da função de transformação para o alargamento de contraste com $w_1 = 0$ e $w_2 = L-1$	36
Figura 9 - Diagrama do processamento realizado.....	39
Figura 10 – Efeito gerado pelo processo de alargamento de contraste	40
Figura 11 – Contornos detectados pelas técnicas MATLAB ACM e ORACM e suas respectivas máscaras de segmentação	41
Figura 12 – Criação da máscara de segmentação dos pulmões.....	41
Figura 13 – Exemplo da extração das lesões.....	42
Figura 14 – Tela inicial da interface MATLAB	45
Figura 15 - Tela de Importação da imagem	46
Figura 16 – Tela Fatia para realização do procedimento para uma fatia do exame. .	47
Figura 17 - Tela de Comparação e apresentação das áreas de lesões detectadas. .	48
Figura 18 – Exemplos de avisos da interface.....	49
Figura 19 – Tela Exame Completo para realização do procedimento para todas as fatias de um exame.	49
Figura 20 - Teste com alargamento de contraste e filtro de média 3x3 para a fatia 00068 do exame 10a_siemens_modiCASGMBH_2mm.....	51
Figura 21 - Teste com alargamento de contraste e filtro de média 3x3 para a fatia 00064 do exame 9a_siemens_modiCASGMBH_2mm.....	52
Figura 22 - Teste com alargamento de contraste e filtro de média 3x3 para a fatia 00071 do exame 11a_siemens_modiCASGMBH_2mm.....	53
Figura 23 - Teste com alargamento de contraste e filtro de mediana 3x3 para a fatia 00068 do exame 10a_siemens_modiCASGMBH_2mm.....	54

Figura 24 - Teste com alargamento de contraste e filtro de mediana 3x3 para a fatia 00064 do exame 9a_siemens_modiCASGMBH_2mm.....	55
Figura 25 - Teste sem alargamento de contraste e com filtro de média 3x3 para a fatia 00068 do exame 10a_siemens_modiCASGMBH_2mm.....	57
Figura 26 - Teste sem alargamento de contraste e com filtro de média 3x3 para a fatia 00064 do exame 9a_siemens_modiCASGMBH_2mm.....	58
Figura 27 - Teste sem alargamento de contraste e com filtro de média 3x3 para a fatia 00071 do exame 11a_siemens_modiCASGMBH_2mm.....	59
Figura 28 - Teste sem alargamento de contraste e com filtro de mediana 3x3 para a fatia 00127 do exame 9a_siemens_modiCASGMBH_2mm.....	61
Figura 29 - Teste sem alargamento de contraste e com filtro de mediana 3x3 para a fatia 00068 do exame 10a_siemens_modiCASGMBH_2mm.....	61
Figura 30 - Teste sem alargamento de contraste e com filtro de mediana 3x3 para a fatia 00071 do exame 11a_siemens_modiCASGMBH_2mm.....	62
Figura 31 - Teste sem alargamento de contraste e com filtro de mediana 3x3 para a fatia 00064 do exame 9a_siemens_modiCASGMBH_2mm.....	63
Figura 32 - Teste exame completo com alargamento de contraste sem filtros para a fatia 00060 do exame 9a_siemens_modiCASGMBH_2mm.....	66
Figura 33 - Teste exame completo com alargamento de contraste sem filtros para a fatia 00143 do exame 9a_siemens_modiCASGMBH_2mm.....	67
Figura 34 - Teste exame completo com alargamento de contraste sem filtros para a fatia 00205 do exame 9a_siemens_modiCASGMBH_2mm.....	68
Figura 35 – Teste exame completo com alargamento de contraste sem filtros para a fatia 00206 do exame 9a_siemens_modiCASGMBH_2mm.....	69
Figura 36 - Teste exame completo com alargamento de contraste sem filtros para a fatia 00153 do exame 10a_siemens_modiCASGMBH_2mm.....	70
Figura 37 - Teste exame completo com alargamento de contraste sem filtros para a fatia 00193 do exame 10a_siemens_modiCASGMBH_2mm.....	71
Figura 38 - Teste exame completo com alargamento de contraste sem filtros para a fatia 00231 do exame 10a_siemens_modiCASGMBH_2mm.....	72
Figura 39 - Teste exame completo com alargamento de contraste sem filtros para a fatia 00098 do exame 11a_siemens_modiCASGMBH_2mm.....	73
Figura 40 - Teste exame completo com alargamento de contraste sem filtros para a fatia 00151 do exame 11a_siemens_modiCASGMBH_2mm.....	74

Figura 41 - Teste exame completo com alargamento de contraste sem filtros para a fatia 00227 do exame 11a_siemens_modiCASGMBH_2mm	75
Figura 42 - Teste exame completo com alargamento de contraste sem filtros para a fatia 00230 do exame 11a_siemens_modiCASGMBH_2mm.....	76
Figura 43 - Teste exame completo sem alargamento de contraste e sem filtros para a fatia 00143 do exame 9a_siemens_modiCASGMBH_2mm	78
Figura 44 – Teste exame completo sem alargamento de contraste e sem filtros para a fatia 00205 do exame 9a_siemens_modiCASGMBH_2mm	79
Figura 45 - Teste exame completo sem alargamento de contraste e sem filtros para a fatia 00206 do exame 9a_siemens_modiCASGMBH_2mm.....	79
Figura 46 – Comparação dos resultados com e sem alargamento de contraste para a fatia 00193 do exame 10a_siemens_modiCASGMBH_2mm	80
Figura 47 - Comparação dos resultados com e sem alargamento de contraste para a fatia 00231 do exame 10a_siemens_modiCASGMBH_2mm	81
Figura 48 - Comparação dos resultados com e sem alargamento de contraste para a fatia 00231 do exame 10a_siemens_modiCASGMBH_2mm.....	82

LISTA DE TABELAS

Tabela 1 - Números tomográficos em HU de diferentes tecidos	20
Tabela 2 - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste com aplicação de filtro de média 3x3 e do alargamento de contraste.....	50
Tabela 3 - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste com aplicação de filtro de mediana 3x3 e do alargamento de contraste.....	53
Tabela 4 - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste com aplicação de filtro de média 3x3 sem alargamento de contraste.	56
Tabela 5 - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste com aplicação de filtro de mediana 3x3 sem alargamento de contraste.	60
Tabela 6 - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste sem aplicação de filtros e sem alargamento de contraste.....	64
Tabela 7 - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM de algumas fatias do teste do exame completo sem aplicação de filtros e com alargamento de contraste.....	65
Tabela 8 - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM de algumas fatias do teste do exame completo sem aplicação de filtros e sem alargamento de contraste.....	77
Tabela 9 – Média e desvio padrão de todas as fatias dos três exames para cada teste.	83
Tabela 10 - Média e desvio padrão de todas as fatias dos três exames para cada teste desconsiderando as fatias que apresentaram erro de detecção quando detecta o contorno externo dos pulmões ao invés das lesões.....	84

LISTA DE ABREVIATURAS E SIGLAS

3D	Tridimensional
ACM	<i>Active contour model</i> ou modelo de contorno ativo
ALF	<i>Adaptive local-fitting method</i>
CAD	<i>Computer-Aided Diagnosis</i> ou diagnóstico assistido por computador
DICOM	<i>Digital Imaging and Communications in Medicine</i>
DPOC	Doença pulmonar obstrutiva crônica
FRBACM	<i>Fuzzy Region-Based active contour model</i>
GLSEPF	<i>The Global and Local Signed Energy-Based Pressure Force</i>
HU	escala de Hounsfield ou <i>Hounsfield units</i>
ITRI	Infecções do trato respiratório inferior
LSACM	<i>Level set active contour model</i>
MAC	<i>Magnetostatic active contour model</i>
MATLAB ACM	função integrada ao MATLAB, <i>activecontour()</i>
ORACM	<i>Online Region based active contour model</i>
RSFOLGE	<i>Region-scalable fitting and optimized Laplacian of Gaussian energy</i>
SBGFRLS	<i>Selective binary and gaussian filtering regularized level set</i>

SUMÁRIO

1	INTRODUÇÃO	16
2	OBJETIVOS	18
	2.2 Objetivos específicos	18
3	REVISÃO BIBLIOGRÁFICA	19
	3.1 Imagem Tomográfica	19
	3.2 Segmentação	21
	3.3 Segmentação de Pulmão em Tomografia Computadorizada	22
	3.4 Métodos De Contornos Ativos	22
	3.4.1 Método ACM tradicional	24
	3.4.2 Método ACM <i>Level-set</i>	26
	3.4.3 <i>Online region based active contour model</i>	27
	3.5 Estado da arte de técnicas de segmentação dos pulmões	29
	3.6 Pré-processamento	31
	3.6.1 Filtros de média e mediana	31
	3.6.2 Alargamento de contraste	34
4	METODOLOGIA	38
5	RESULTADOS E DISCUSSÃO	45
	5.1 Interface MATLAB	45
	5.2 Bloco de Testes 01: Testes Preliminares	50
	5.2.1 Teste com alargamento de contraste e filtro de média 3x3	50
	5.2.2 Teste com alargamento de contraste e filtro de mediana 3x3	53
	5.2.3 Teste sem alargamento de contraste e com filtro de média 3x3	56
	5.2.4 Teste sem alargamento de contraste e com filtro de mediana 3x3	60
	5.2.5 Teste sem alargamento de contraste e sem filtros	63
	5.3 Bloco de Testes 02: Testes Exame Completo	64
	5.3.1 Teste exame completo com alargamento de contraste	65

5.3.2	Teste exame completo sem alargamento de contraste.....	76
5.4	Média e desvio padrão.....	83
6	DISCUSSÃO	85
7	CONCLUSÃO	87
	REFERÊNCIAS.....	89
	APÊNDICE – RESULTADOS EXAMES COMPLETOS	93

1 INTRODUÇÃO

Das dez posições do ranking de causas globais de morte em 2019, três incluem doenças que atingem o sistema respiratório: doença pulmonar obstrutiva crônica (DPOC); infecções do trato respiratório inferior (ITRI); e câncer de traqueia, brônquios e pulmonar. A DPOC, composta por um grupo de doenças pulmonares que bloqueiam o fluxo de ar e dificultam a respiração como a bronquite crônica e o enfisema, é a terceira principal causa de morte, responsável por 3,22 milhões de mortes (MINISTÉRIO DA SAÚDE, [s. d.]; WORLD HEALTH ORGANIZATION, 2020, 2021).

As infecções do trato respiratório inferior incluem todas as infecções que afetam as vias áreas abaixo da caixa de voz e pulmões, como pneumonia, bronquite, tuberculose e gripe (ABBOTT, 2021; FLETCHER, 2019). Apesar do número de mortes causadas pelas ITRI ter diminuído desde 2000, elas continuaram a ser a doença transmissível mais mortal do mundo, ocupando a quarta posição do ranking com 2,59 milhões de mortes. Dentro das doenças não transmissíveis, as mortes causadas por câncer de traqueia, brônquios e pulmonar aumentaram 1,2 milhões para 1,76 milhões, ocupando o sexto lugar entre as principais causas de morte (WORLD HEALTH ORGANIZATION, 2020, 2021).

Além disso, considerando as mortes causadas pela COVID-19 em número absoluto no ano de 2020, a doença ocuparia o sexto lugar no ranking com 1,8 milhões de mortes (WORLD HEALTH ORGANIZATION, 2021). Esta doença atinge principalmente o sistema pulmonar, podendo gerar efeitos que, a longo prazo, afetam diversos sistemas do organismo humano (NALBANDIAN *et al.*, 2021).

Ainda, as estimativas da Organização Mundial de Saúde de 2022 indicam que a pandemia da COVID-19 está diminuindo a tendência de aumento da expectativa de vida e da expectativa de vida saudável. Quando comparado com 2019, estudos recentes constataram que a COVID-19 reduziu a expectativa de vida em 2020 em mais de 6 meses em alguns países das Américas e da Europa (WORLD HEALTH ORGANIZATION, 2022).

Assim, a identificação e diagnóstico precoce dessas doenças, o que possibilita realização do tratamento com maior probabilidade de cura e sobrevivência, é essencial para reduzir essa mortalidade. Para a avaliação de lesões pulmonares geradas por essas doenças, utiliza-se técnicas de imagem tais como radiografia de

tórax e tomografia computadorizada de tórax. Apesar das imagens radiográficas serem mais acessíveis, as imagens tomográficas permitem a discriminação dos tecidos moles e a visualização de padrões morfológicos do parênquima pulmonar (KROFT *et al.*, 2019).

Com o propósito de auxiliar os radiologistas na detecção da infecção e na avaliação da progressão da doença, desenvolveu-se o interesse na extração automática e na interpretação computadorizada da região de interesse pulmonar, beneficiando o diagnóstico e o tratamento precisos (ZHAO *et al.*, 2021). Além disso, a obtenção da região de infecção reduzirá o tempo de análise dos resultados dos testes por parte dos radiologistas, que pode ser obtida através de algoritmos de segmentação (AKBARI *et al.*, 2021).

2 OBJETIVOS

Este estudo visa realizar a segmentação e caracterização dos pulmões e lesões pulmonares, comparando duas técnicas de segmentação de imagens baseadas em contorno ativo para aplicação em imagens de tomografia computadorizada de pulmão, assim como desenvolver uma interface gráfica para facilitar a seleção de diferentes técnicas de pré-processamento.

2.2 Objetivos específicos

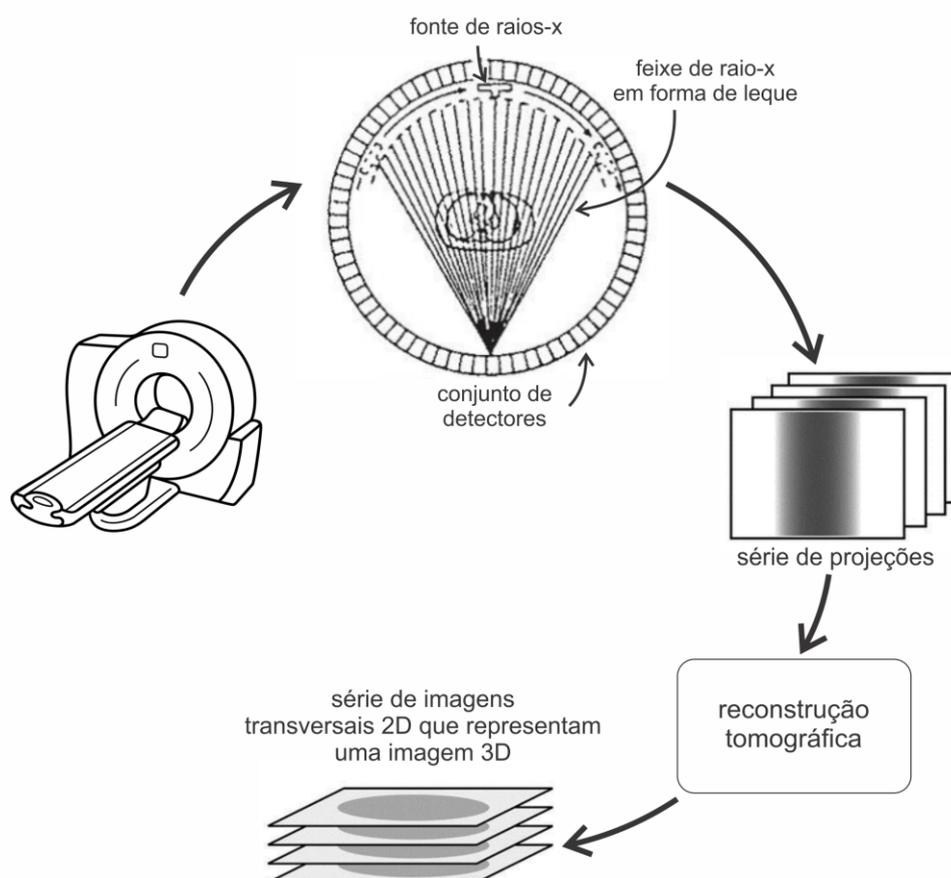
- Avaliar a influência dos filtros de média e mediana, aplicados no pré-processamento, na detecção dos pulmões e das lesões pulmonares pelos métodos de contorno ativo;
- Avaliar a influência da aplicação do alargamento de contraste no pré-processamento;
- Extrair a área de lesões que foram detectadas;
- Avaliar comparativamente as técnicas de contorno ativo *Online region active contour* e a função incorporada ao MATLAB *activecontour()*;
- Testar as técnicas de segmentação em exames de tomografia de tórax completos;
- Implementar uma interface MATLAB que permita a seleção dos processamentos, facilitando a interação e compartilhamento do algoritmo.

3 REVISÃO BIBLIOGRÁFICA

3.1 Imagem Tomográfica

A imagem tomográfica é formada fazendo-se uma varredura de uma fatia de tecido em múltiplas direções, usando um feixe estreito de raios X em forma de leque para obtenção de imagens transversais (Figura 1). Assim, obtém-se as projeções do objeto em estudo com os dados coletados de cada direção, e reconstrói-se a imagem transversal a partir das múltiplas projeções. Com a somatória de diversas imagens transversais é possível visualizar os dados como imagens em qualquer plano e como uma imagem tridimensional (DOUCHERTY, 2009). Logo, a imagem tomográfica é uma representação tridimensional de um volume a partir das imagens de cada fatia do objeto, obtidas através da soma de múltiplas projeções (GONZALEZ; WOODS, 2010 e HSIEH, 2009).

Figura 1 - Esquema do processo de aquisição e reconstrução da imagem tomográfica



Fonte: autoria própria.

Para geração das projeções, a tomografia computadorizada faz o uso dos raios X que são transmitidos através do corpo, absorvidos, conforme o grau de atenuação gerado pelo tecido por onde os raios passaram, e captados pelos detetores. Dessa forma, obtém-se as intensidades dos raios que chegam aos sensores de acordo com o grau de atenuação gerado pelos processos de absorção e espalhamento dos raios conforme estes atravessam o paciente (BEUTEL; KUNDEL; METTER, 2000).

Essa intensidade transmitida pode ser calculada por meio da Equação 3.1.1:

$$I_{transmitida} = I_0 \cdot e^{-\int_0^L \mu(x) dx} \quad (3.1.1)$$

em que $I_{transmitida}$ é a intensidade do feixe transmitido; I_0 é a intensidade do feixe incidente; L é a espessura do objeto; e $\mu(x)$ corresponde ao coeficiente de atenuação linear dos raios X que varia de acordo com os tecidos (BEUTEL; KUNDEL; METTER, 2000).

O coeficiente de atenuação linear dos raios X é medido na escala de Hounsfield (HU) que vai de -1000 a 1000, com a intensidade da água igual à 0 HU, a do ar igual à -1000 HU e a do osso igual à 1000, obtendo-se valores em HU para todos os outros tecidos, conforme mostrado na Tabela 1.

Tabela 1 - Números tomográficos em HU de diferentes tecidos

Tecido	HU
Osso cortical	250 a 1000+
Osso trabecular	100 a 250
Matéria branca	20 a 30
Matéria cinzenta	35 a 45
Sangue	55 a 75
Rim	20 a 40
Pâncreas	30 a 55
Fígado	55 a 80
Líquido cefalorraquidiano	0 a 10
Água	0
Pulmão	-500 a -900
Gordura	-50 a -100
Ar	-1000

Fonte: adaptado de KALRA (2018)

Por fim, utilizando-se a intensidade transmitida, reconstrói-se as projeções com os dados capturados pelos detetores por meio da transformada de Randon e gera-se uma fatia tomográfica a partir da soma das imagens transversais (GONZALEZ; WOODS, 2010; HSIEH, 2009).

Vale ressaltar que, devido ao encapsulamento da imagem digital e dos dados em um cabeçalho gerados pelo padrão de tratamento e armazenamento de imagens médicas DICOM, pode-se recuperar diversas informações, além da imagem tomográfica, como o tipo de imagem, o fabricante, o modelo do equipamento, o fármaco utilizado como agente de contraste etc., (ANASTÁCIO, 2015).

3.2 Segmentação

A segmentação de uma imagem é o processo no qual a imagem original é separada em regiões significativas, normalmente para diferenciar objetos ou regiões de interesse no primeiro plano do plano de fundo. Para tal, faz-se o uso de atributos que definirão as regiões a serem segmentadas, como nível de cinza, cor, bordas, textura, brilho e contraste da imagem (DOUCHERTY, 2009; SILVA; PATROCÍNIO; SCHIABEL, 2019).

Na medicina, a segmentação pode ser utilizada para detecção de órgãos, como o coração, os pulmões ou o fígado; ou distinguir tecidos patológicos, como tumores ou nódulos; auxiliando no planejamento de tratamentos. Ainda, muitos sistemas de reconhecimento de padrões ou de *machine learning* utilizam a segmentação no pré-processamento a fim de facilitar a caracterização e classificação dos objetos em grupos ou classes (DOUCHERTY, 2009).

Existem muitas abordagens de segmentação de acordo com os atributos e técnicas que são utilizados. Há técnicas que utilizam um atributo global para agrupar os pixels, sem considerar as relações entre as características da imagem, que é o caso da segmentação por *thresholding* (limiar). Há outras técnicas que avaliam as relações entre as características da imagem, podendo-se agrupar pixels com propriedades semelhantes segundo uma medida extraída da imagem (como média móvel, moda, desvio padrão), ou segundo valores de intensidade semelhantes, ou, ainda, segundo variações abruptas de intensidade na imagem para segmentar as regiões. Exemplos dessas abordagens são: segmentação por *watershed*, por *clustering* (agrupamento), baseada por região, baseada por borda, por *Support Vector*

Machine e por contornos ativos (DOUCHERTY, 2009; LAVANYA; KANNAN, 2017; SILVA; PATROCÍNIO; SCHIABEL, 2019).

3.3 Segmentação de Pulmão em Tomografia Computadorizada

Através da tomografia do tórax, doenças pulmonares e da caixa torácica, como pneumonia, embolia pulmonar, asma, tuberculose, tumores benignos e malignos, são identificadas e diagnosticadas (ALTA DIAGNÓSTICOS, [s. d.]). Dessa forma, a obtenção das lesões ou regiões de infecção nos pulmões, por meio de algoritmos de segmentação, pode auxiliar e facilitar a caracterização, bem como reduzir o tempo de análise para diagnosticar essas doenças (AKBARI *et al.*, 2021; REBOUÇAS FILHO, 2013). Este auxílio ao diagnóstico também permite o aumento das informações sobre o estado da doença, aumentando, assim, a precisão do diagnóstico feito pelo médico. Além disso, possibilita a observação da evolução da doença (REBOUÇAS FILHO, 2013).

Conforme explicado anteriormente, uma imagem tomográfica dos pulmões irá representar uma fatia da caixa torácica, apresentando outras estruturas dessa região como vasos, pleura, parênquima pulmonar etc., sendo necessário isolar os pulmões para analisar e caracterizar as informações específicas referente a eles (REBOUÇAS FILHO, 2013).

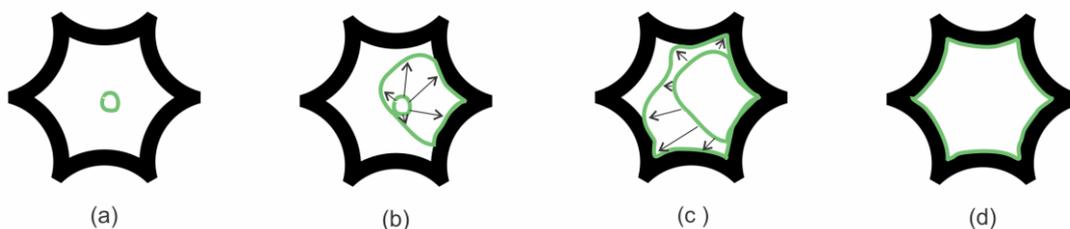
Além disso, com a obtenção da segmentação dos pulmões para cada imagem transversal de um exame completo, é possível reconstruir um modelo tridimensional dos pulmões em análise, permitindo a visualização da anatomia completa dos pulmões do paciente (REBOUÇAS FILHO, 2013).

3.4 Métodos De Contornos Ativos

O modelo *snake* de contorno ativo (ACM, do inglês, *Active Contour Model*) é uma das abordagens que apresenta um desempenho estável para a segmentação. Este método fundamenta-se na construção de segmentos de retas até os limites da área interna da região a ser segmentada (Figura 2). Assim, após inicialização do contorno em torno ou dentro do objeto desejado, este continua a ser moldado conforme a forma da região a ser segmentada, de acordo com os deslocamentos dos pontos de controle que orientam os segmentos de retas. A técnica é chamada de

snake devido ao comportamento dos deslocamentos serem semelhantes ao deslocamento de uma cobra (AKBARI *et al.*, 2021; DE ALEXANDRIA *et al.*, 2011).

Figura 2 - Representação do funcionamento dos métodos de contornos ativos, (a) inicialização da curva dentro do objeto, (b) e (c) representam as interações intermediárias; e (d) representa o resultado final da segmentação. As setas representam as direções em que alguns pontos controle se movimentam para chegar às fronteiras do objeto analisado.



Fonte: autoria própria.

Para moldar o contorno inicial em direção aos limites do objeto, busca-se a curva de menor energia funcional total, que é uma função das energias internas e externas do contorno, atualizando a curva ponto-a-ponto a cada interação sucessiva. A energia caracterizada como energia interna depende da geometria do *snake*. Já a energia caracterizada como externa depende das características da imagem. Dessa forma, a vizinhança de cada ponto é analisada, calculando as energias internas e externas envolvidas, deslocando o contorno para a coordenada que possuir a menor energia funcional total na vizinhança do ponto analisado, conforme as equações 3.4.1 e 3.4.2 (AKBARI *et al.*, 2021; DE ALEXANDRIA *et al.*, 2011; KASS; WITKIN; TERZOPOULOS, 1987):

$$E = \sum_{s=0}^N (E_{int}[c(s)] + E_{ext}[c(s)]) \quad (3.4.1)$$

em que E_{int} se refere às energias internas da curva, E_{ext} às energias externas e c à curva na qual a posição de cada ponto $c(s)$ na imagem é determinada pelas coordenadas $x(s)$ e $y(s)$, assim:

$$c(s) = [x(s), y(s)] \quad (3.4.2)$$

e, portanto, a energia de cada ponto da curva será

$$E[c(s)] = E_{int}[c(s)] + E_{ext}[c(s)] \quad (3.4.3)$$

em que E é a energia funcional total, E_{int} se refere às energias internas do ponto $c(s)$ e E_{ext} às energias externas neste mesmo ponto.

Como os pontos da curva são atualizados a cada interação sucessiva, os modelos de contornos ativos são modelos deformáveis que podem ser classificados em quatro categorias conforme a representação do contorno, paramétrica ou de nível, e a descrição dos limites do objeto, orientada por borda ou por região (AKBARI *et al.*, 2021).

No ACM paramétrico, o contorno é representado por polinômios ou *splines*. As energias externas são responsáveis por impulsionar a evolução do contorno paramétrico, enquanto as energias internas definem a forma do contorno. Entretanto, as *snakes* paramétricas tem um alcance de captura limitado, conseguindo extrair apenas um objeto próximo do contorno de inicialização, além de serem ineptas de extraírem formas côncavas (AKBARI *et al.*, 2021). No ACM de nível, o contorno é representado por uma função de nível. Ao contrário do ACM paramétrico, o ACM de nível permite extrair múltiplos objetos complexos a partir do contorno inicial. Porém, exigem, para tal, maior processamento matemático computacional, sendo mais lentos que os métodos paramétricos (AKBARI *et al.*, 2021).

Os modelos orientados por bordas utilizam informações locais das bordas do objeto para deslocar o contorno até elas. Já os modelos orientados por regiões utilizam informações mais globais para definir limites de objetos, empregando informações estatísticas dentro e fora do contorno para modelá-lo. Esta abordagem é menos sensível à localização do contorno inicial, conseguindo detectar, com mais precisão, os limites internos e externos, comparando-se com os métodos baseados nas bordas (AKBARI *et al.*, 2021; MESQUITA, 2012).

3.4.1 Método ACM tradicional

No modelo ACM Tradicional, minimiza-se a função da energia da curva inicial, modelando-se a curva (*snake*) de tal forma que sua energia funcional diminui a cada interação. Como visto anteriormente, essa energia é composta por uma energia

interna e uma energia externa, dependendo apenas da forma da curva e da localização de seus pontos (DE ALEXANDRIA *et al.*, 2011).

A energia interna é composta por duas outras energias ou forças E_1 e E_2 . A primeira (Equação 3.4.1.1) está relacionada à elasticidade ou resistência da curva ao ser deformada, podendo ser chamada de força de elasticidade ou força de continuidade. Assim, esta força exprime a capacidade de um ponto da curva se afastar ou aproximar de seus vizinhos (DE ALEXANDRIA *et al.*, 2011; REBOUÇAS FILHO, 2013).

$$E_1 = \int \alpha |c'(s)|^2 ds \quad (3.4.1.1)$$

A segunda energia (Equação 3.4.1.2), está ligada à suavização ou curvatura do *snake*, podendo ser chamada também de Força de Curvatura. Esta força deixa a curva contínua e suave de acordo com seus ângulos internos aumentando ou diminuindo a curvatura da curva. De fato, esta componente atinge seu mínimo quando $c''(s) = 0$, ou seja, quando $c(s) = ks$ e, como k é uma constante, c é uma reta. Assim, favorecer o coeficiente E_2 durante a minimização, força a curva a diminuir sua curvatura (DE ALEXANDRIA *et al.*, 2011; REBOUÇAS FILHO, 2013).

$$E_2 = \int \beta |c''(s)|^2 ds \quad (3.4.1.2)$$

A relevância de cada parcela da energia interna do ponto $c(s)$ é determinada por α e β .

A energia externa permite adaptar a curva sobre o contorno dos objetos, podendo ser definida de diversas formas, utilizando informações como os níveis de cinza dos pixels ou as bordas do objeto. A forma mais comum é calcular a energia externa utilizando o quadrado do gradiente da imagem no ponto da curva (KASS; WITKIN; TERZOPOULOS, 1987):

$$E_{ext}(x, y) = -|\nabla[I(x, y)]|^2 \quad (3.4.1.3)$$

também pode-se aplicar uma gaussiana visando espalhar a influência da energia ao longo da vizinhança do ponto em que ela é aplicada:

$$E_{ext}(x, y) = -|\nabla[G_\sigma \cdot I(x, y)]|^2 \quad (3.4.1.4)$$

onde ∇ é o operador gradiente e G_σ é uma gaussiana centrada no ponto (x, y) de variância σ^2 .

Entretanto, os ACMs tradicionais apresentam limitações como a necessidade de inicialização próximo ao objeto de interesse e limitação da flexibilidade da curva, impedindo a extração de bordas convexas, saliências ou bifurcações (REBOUÇAS FILHO, 2013).

3.4.2 Método ACM *Level-set*

O método *level-set* é um modelo de segmentação de contornos implícitos que permite formar um modelo geométrico através da utilização de uma curva paramétrica embutida em uma superfície, assim, o contorno inicial (uma curva simples em um plano 2D) está embutido em uma função de maior dimensão (uma superfície 3D) (BERTUOL, 2007; LANKTON, 2009; MESQUITA, 2012).

Para tal, adiciona-se mais uma coordenada à curva inicial $c(x, y)$, formando-se uma nova curva fronteira $\phi(x, y, t)$. Para $t = 0$, o nível inicial $\phi(x, y, 0)$ será igual à curva inicial $c(x, y)$, obtendo-se um valor inicial para cada ponto (x, y) da nova fronteira $\phi(x, y, 0)$ baseado na distância de cada ponto à curva inicial (BERTUOL, 2007; MESQUITA, 2012). Assim, a curva $c(x, y)$ passa a ser uma curva de nível embutida em ϕ por meio, tipicamente, de uma função de distância assinada com sinal (BERTUOL, 2007; LANKTON, 2009):

$$\phi(x, y) = \begin{cases} -\text{sign}(x, y, c), & \text{se } (x, y) \text{ está fora de } c \\ \text{sign}(x, y, c), & \text{se } (x, y) \text{ está dentro de } c \end{cases}$$

em que $\text{sign}(x, y, c)$ refere-se à distância do ponto (x, y) ao ponto mais próximo da curva c . Essa distância pode ser determinada pela distância Euclidiana, por exemplo. Normalmente, opta-se por esta função pois permite obter a primeira e a segunda derivadas de forma simples.

Dessa forma, pelo sinal de ϕ é possível determinar se um ponto está dentro ou fora da região definida pela curva inicial, auxiliando no processo de segmentação.

Ainda, outra vantagem desse método é a possibilidade de utilizar mais de uma curva inicial para representar a região, mesmo que as curvas se unam em certo ponto já que estas estão embutidas em ϕ , permitindo segmentação de regiões não conectadas entre si (BERTUOL, 2007).

Contudo, o método *level-set* requer muitos cálculos, sendo algoritmos lentos. Pensando na redução da complexidade computacional, surgiram novas abordagens baseadas em algoritmos *narrow-band* que reduzem a complexidade computacional por realizarem cálculos próximos do nível zero (LANKTON, 2009).

Ainda, a função MATLAB *activecontour()*, utilizada neste trabalho para uma das segmentações por meio de contorno ativo, é baseada em uma outra abordagem *level-set*: *Level-Set Sparse Field*, desenvolvido por Whitaker (1998). Este método utiliza listas de pontos de grade, que representam o conjunto de nível zero, assim como pontos adjacentes ao conjunto de níveis zero.

Assim, a superfície pode ser representada como um campo 3D ou como um subconjunto desse campo 3D, que será formado por um conjunto de pontos de grade, chamados de pontos ativos. Durante o processo de deformação do nível zero, considera-se apenas uma fina camada de subconjuntos perto dos pontos ativos, atualizando o contorno.

É desse modo que a complexidade computacional é reduzida, já que ela crescerá com a dimensionalidade da superfície e não do volume, como acontece com o método tradicional do *level-set*. Além disso, as listas de pontos adjacentes podem ser acessadas de forma rápida e eficiente através de uma lista de pontos ativos vinculada (LANKTON, 2009; WHITAKER, 1998).

3.4.3 *Online region based active contour model*

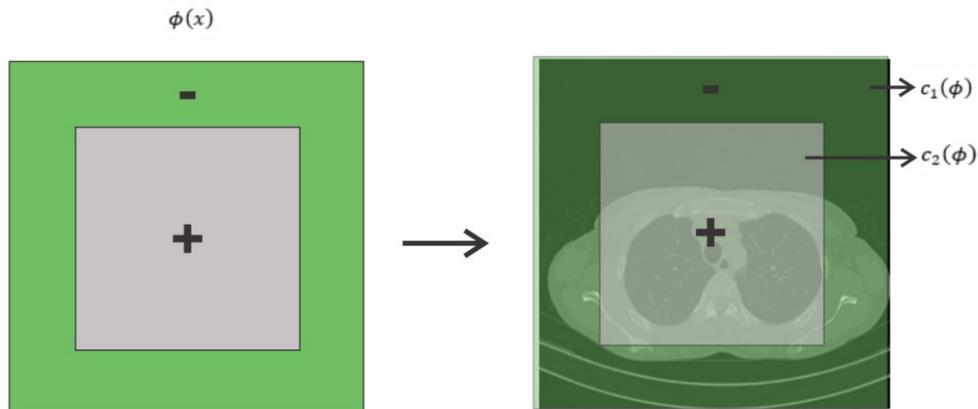
O *Online Region-based Active Counter Model* (ORACM) é uma abordagem de contorno ativo baseado em região que, comparado com os ACMs tradicionais, não exige parâmetros e leva menos tempo para segmentar sem mudar a precisão (TALU, 2013).

Este método realiza um limiar em blocos (*block thresholding*) em cada interação, atualizando o contorno inicial continuamente. Porém, esse processo gera bordas e pequenas partículas que não pertencem ao objeto. Para contornar esse problema são utilizadas operações morfológicas de abertura e fechamento, uma

ferramenta que permite a extração de componentes da imagem úteis para a representação e descrição da forma de uma região, obtendo-se um contorno suave e adequado do objeto (TALU, 2013).

Como não é preciso especificar parâmetros, a técnica faz uso de uma função de ajuste de nível $\phi(x)$ que é inicializada com as constantes -1, para fora do contorno, e +1, dentro do contorno, conforme a Figura 3:

Figura 3 – Ilustração da função de ajuste de nível $\phi(x)$.



Fonte: adaptado de Talu (2013).

Para atualizar o contorno inicial, faz uso da função Heaviside $H(\cdot)$, também chamada de função degrau, juntamente com a função de pressão $spf(\cdot)$ para cada nível ϕ atual da imagem de entrada $I(x)$, conforme a equação 3.4.8(TALU, 2013):

$$\frac{\partial \phi}{\partial x} = H\left(sp f(I(x))\right) \cdot \phi(x) \quad (3.4.8)$$

em que $spf(\cdot)$ é definida por:

$$spf(I(x, y)) = \frac{I(x, y) - \frac{c_1 + c_2}{2}}{\max\left(I(x, y) - \frac{c_1 + c_2}{2}\right)} \quad (3.4.9)$$

com

$$c_1(\phi) = \frac{\int^I(x) \cdot H(\phi) dx}{\int^H(\phi) dx} \quad e \quad c_2(\phi) = \frac{\int^I(x) \cdot (1 - H(\phi)) dx}{\int^H(1 - H(\phi)) dx} \quad (3.4.10 \text{ e } 3.4.11)$$

Este método traz as vantagens de aumentar a eficiência, sem alterar a precisão da segmentação, e de segmentar diferentes regiões de objetos em imagens médicas, reais e sintéticas, com fundo complexo, bordas fracas e altos ruídos (AKBARI *et al.*, 2021). Entretanto, este método suporta apenas a segmentação bimodal de distribuição de intensidade constante, isto é, a segmentação baseada no histograma de uma imagem que apresenta um pico que caracteriza os objetos e outro pico que caracteriza o fundo, possuindo tons de cinza intermediários não predominantes (TALU, 2013).

3.5 Estado da arte de técnicas de segmentação dos pulmões

Existem diversos estudos para realização da segmentação no auxílio ao diagnóstico do câncer de pulmão, contudo, com a pandemia da COVID-19, diversos autores passaram a explorar a segmentação de lesões pulmonares causadas pela pneumonia consequente da COVID-19. Ainda, outro desafio muito explorado é o desenvolvimento de um único software CAD que consiga avaliar diferentes tipos de lesões pulmonares.

O trabalho de Akbari *et al* (2021) avalia a infecção por pneumonia causada pelo COVID-19 por meio da utilização modelos de contornos ativos em imagens tomográficas, comparando os desempenhos de diversos métodos recentes de contorno ativo: *C-V model*, *Selective binary and gaussian filtering regularized level set* (SBGFRLS), *Magnetostatic active contour model* (MAC), *Online region-based active contour model* (ORACM), *Level set active contour model* (LSACM), *Region-scalable fitting and optimized Laplacian of Gaussian energy* (RSFOLGE), *Adaptive local-fitting method* (ALF), *Fuzzy Region-Based active contour model* (FRBACM), *The Global and Local Signed Energy-Based Pressure Force* (GLSEPF).

Inicialmente, os autores fizeram a extração da região pulmonar removendo os artefatos da imagem teste, como ossos e outros segmentos do corpo, utilizando um filtro de limiar feito por Rajinikanth *et al.* (2020). Este filtro de limiar separa a imagem de teste em duas seções, com base em um limiar selecionado manualmente. A

seleção do limiar é feita por tentativa e análise de erro, para funcionar com todas as imagens consideradas pelos autores. Ainda, para comparar as abordagens em questão, foram aplicadas as medidas estatísticas de similaridade, medidas de precisão, iteração e tempo entre outras (AKBARI *et al.*, 2021).

Em uma avaliação geral, o ORACM obteve os melhores resultados em comparação com outros métodos, tanto em avaliações quantitativas como qualitativas. Os resultados demonstraram que o ORACM apresenta um desempenho consideravelmente melhor que as outras técnicas de uma maneira geral, conseguindo preservar os limites melhor do que os outros métodos. Ainda, na análise qualitativa, os autores concluíram que os métodos ORACM, FRBACM e GLSEPF são mais eficazes e podem produzir uma qualidade visual superior (AKBARI *et al.*, 2021).

Outro estudo que se baseou nos modelos de contornos ativos foi o estudo de Hatamizadeh *et al.* (2019), que desenvolveu um framework totalmente automatizado para segmentação, utilizando a determinação de limites dos ACMs juntamente com a capacidade de extração de características e padrões das técnicas de aprendizado de máquina de redes neurais convolucionais.

Com relação aos recentes métodos supervisionados, existe uma ampla gama de aplicações baseadas em aprendizado de máquinas, que contribuem com o diagnóstico da COVID-19 e do câncer de pulmão; entretanto, essas abordagens exigem uma grande quantidade de imagens anotadas para serem treinadas e atingirem um nível alto de precisão, existindo programas pouco maduros para a detecção de lesões dependendo da aplicação (OULEFKI *et al.*, 2021). Zheng *et al.* (2020) elaboraram um software baseado no aprendizado profundo de máquinas e pouco supervisionado (*weakly-supervised deep learning*) para detecção do COVID-19 por meio de volumes 3D de imagens tomográficas. Oulefki *et al.* (2021) desenvolveram uma ferramenta para segmentação e medição automática da infecção pulmonar COVID-19 usando imagens de tomografia computadorizada do tórax, baseando-se no aprendizado de máquinas juntamente com a técnica de limiares multiníveis baseados na entropia de Kapur, otimizando esta última.

Com relação a outras abordagens, Lavanya e Kannan (2017) implementaram um método baseado no algoritmo *Fuzzy Local Information Cluster Means* para detecção e segmentação de lesões de tumores pulmonares por meio de tomografias computadorizadas. Já Jolly e Grady (2008) propuseram um algoritmo geral, semiautomático, para segmentação de qualquer tipo de lesão em tomografias, que

reuniu diferentes abordagens como o algoritmo Random Walker e o algoritmo de conectividade difusa juntamente com uma técnica multi-sementes.

Além disso, existem muitos outros estudos que avaliam e desenvolvem técnicas e abordagens diferentes para realização e obtenção de uma segmentação precisa.

3.6 Pré-processamento

O pré-processamento é um estágio preparatório para a realização da extração e interpretação de informações contidas nas imagens, fornecendo melhores informações visuais para os olhos humanos ou obtendo imagem de entrada corrigidas e realçadas para os sistemas de processamento de imagens automatizados. Assim, é através do pré-processamento que a imagem é preparada para as fases seguintes que identificarão as estruturas e objetos de interesse (CRÓSTA, 1992; EL REGAILY *et al.*, 2017; SILVA; PATROCÍNIO; SCHIABEL, 2019). É nesta etapa que a imagem tem seu contraste melhorado, pixels defeituosos corrigidos, ruídos reduzidos, permitindo o aumento da eficiência das técnicas de processamento conseguintes (SILVA; PATROCÍNIO; SCHIABEL, 2019).

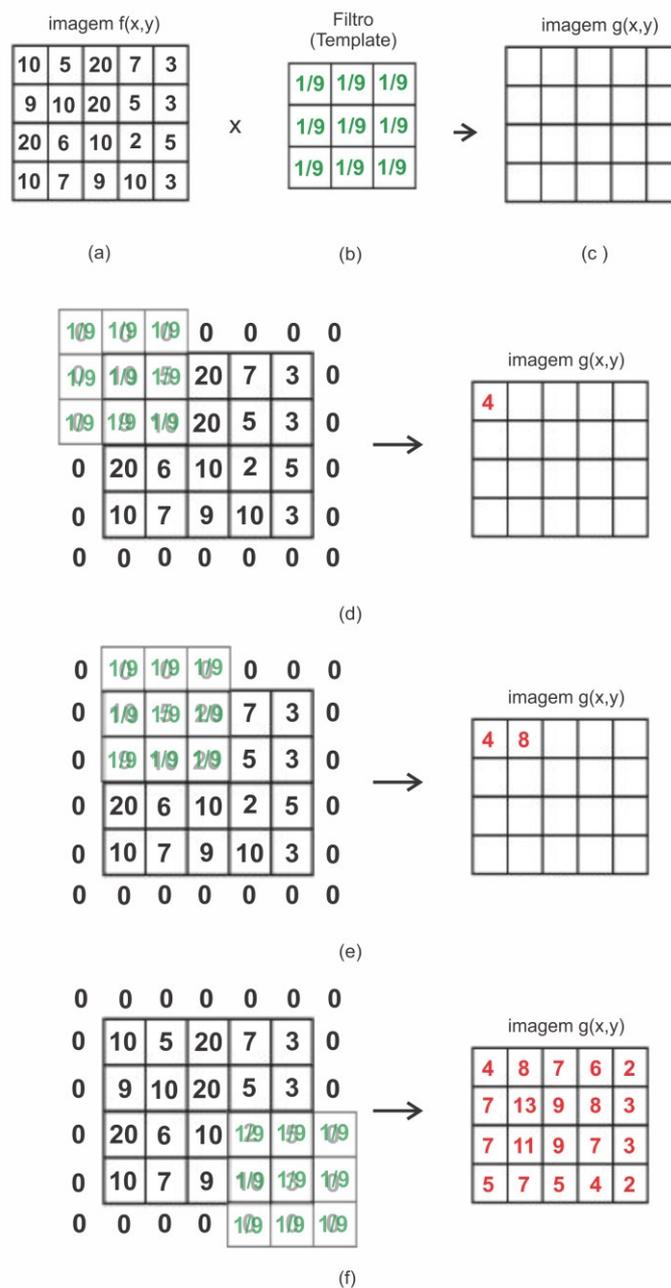
3.6.1 Filtros de média e mediana

Uma das técnicas mais utilizadas no pré-processamento são os filtros. Esta técnica possibilita a retirada ou diminuição de componentes indesejados, como os artefatos e ruídos, ou a extração ou evidência de elementos da imagem, como suas bordas. Para trabalhar com os filtros, pode-se realizar as operações no domínio do espaço ou no domínio da frequência. No primeiro, a imagem é representada por uma matriz de tons de cinza ou intensidades de cor cujas coordenadas correspondem com o espaço onde o sinal é amostrado. No segundo domínio, as operações são realizadas considerando-se a taxa de mudança de intensidade dos pixels (SILVA; PATROCÍNIO; SCHIABEL, 2019).

Os filtros de média e mediana são filtros espaciais de suavização. Para tais operações, utiliza-se uma máscara que define a vizinhança de pixels que será considerada no mapeamento de novos valores de pixels (SILVA; PATROCÍNIO; SCHIABEL, 2019). Ou seja, os valores dos pixels da imagem original serão

modificados de acordo com uma manipulação de uma vizinhança de pixels por meio de uma máscara.

Figura 4 - Esquema exemplo de aplicação de filtro de média 3x3



Fonte: autoria própria.

No caso do filtro de média, os valores dos pixels originais são substituídos pela média aritmética dos pixels com seus vizinhos. No caso do filtro de mediana, o pixel em análise seria substituído pela mediana do pixel com seus vizinhos (CRÓSTA, 1992).

Exemplificando essa operação para um filtro de média 3x3, tem-se uma imagem $f(x, y)$, representada por uma matriz de pixels com x linhas e y colunas, e uma máscara template, conforme mostrado na Figura 4 (a) e (b).

Uma nova imagem processada (Figura 4 (c)), isto é, uma imagem filtrada, será gerada à medida que o centro do filtro *template* percorre cada pixel da imagem de entrada $f(x, y)$; por meio de uma convolução. Assim, para tal operação, coloca-se o centro da máscara template sobre o primeiro pixel da imagem, sobrepondo-a na imagem de entrada e multiplica-se o índice da máscara pelo valor correspondente da imagem, como mostrado na Figura 4 (d). Para não gerar um erro nas operações, preenche-se com uma linha de zeros ao redor de toda a imagem (Figura 4 (d)).

Então, para o primeiro pixel $f(1, 1)$ com valor 10, tem-se a geração de um novo pixel na imagem processada $g(x, y)$ na posição (1, 1) igual à:

$$g(1,1) = 0 * \frac{1}{9} + 0 * \frac{1}{9} + 0 * \frac{1}{9} + 0 * \frac{1}{9} + 10 * \frac{1}{9} + 5 * \frac{1}{9} + 0 * \frac{1}{9} + 9 * \frac{1}{9} + 10 * \frac{1}{9} = 3,8 = 4$$

No próximo pixel, desloca-se o centro da máscara para o lado no pixel $f(2,2)$, como mostrado na Figura 4 (e), fazendo-se as mesmas operações:

$$g(1,2) = 0 * \frac{1}{9} + 0 * \frac{1}{9} + 0 * \frac{1}{9} + 10 * \frac{1}{9} + 5 * \frac{1}{9} + 20 * \frac{1}{9} + 9 * \frac{1}{9} + 10 * \frac{1}{9} + 20 * \frac{1}{9} = 8,2 = 8$$

Aplicando este procedimento para todos os pixels da imagem de entrada, obtém-se a imagem filtrada $g(x, y)$, como mostrada na Figura 4 (f).

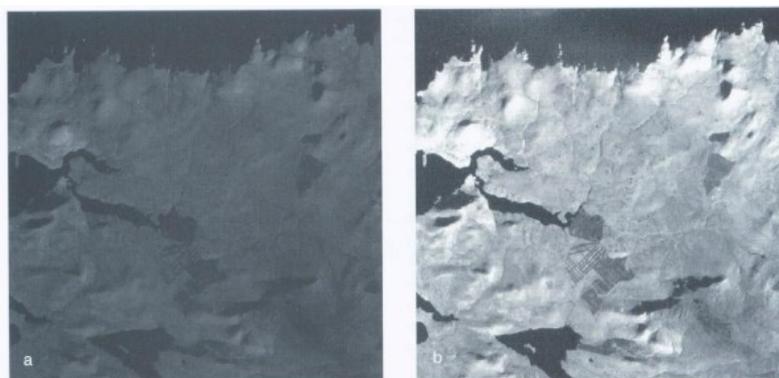
Esse processo de cálculo da médio ou mediana gera menores diferenças entre as cores dos pixels vizinhos e, conseqüentemente, reduz as transições abruptas de intensidade, formando uma imagem suavizada. Por isso, esses filtros são chamados de filtros de suavização. Contudo, esse tipo de filtro gera um efeito de desfoque das bordas da imagem, que são caracterizadas por transições abruptas de intensidade, perdendo-se informações de detalhe. Ainda, tal efeito de suavização é diretamente proporcional ao tamanho da máscara utilizada. Assim, uma máscara 9x9 produzirá um efeito de desfoque muito maior do que uma máscara 3x3. Um dos filtros de suavização que melhor preserva as bordas da imagem é o filtro de mediana (CRÓSTA, 1992; SILVA; PATROCÍNIO; SCHIABEL, 2019).

3.6.2 Alargamento de contraste

Outra técnica utilizada como uma etapa do pré-processamento para sistemas de reconhecimento de padrões e caracterização de regiões de interesse é o método de alargamento de contraste. Esta técnica permite o aprimoramento da imagem, melhorando o contraste em uma imagem através do estiramento da faixa de valores de intensidade que ela contém para abranger uma faixa de valores desejada (ANASTÁCIO, 2015; PRASAD, [s. d.]; SPRING, 2006).

Contraste é a razão entre os níveis de cinza médios de dois objetos, ou seja, a diferença de intensidade entre os pixels escuros e claros desses objetos. Assim, a manipulação do contraste permite aumentar a diferenciação visual entre os objetos presente na imagem, realizando uma operação ponto a ponto. Portanto, após a aplicação do alargamento de contraste, a imagem resultante exibe um contraste maior entre as características de interesse de acordo com a faixa selecionada (Figura 5), facilitando a detecção de estruturas e padrões (PRASAD, [s. d.]).

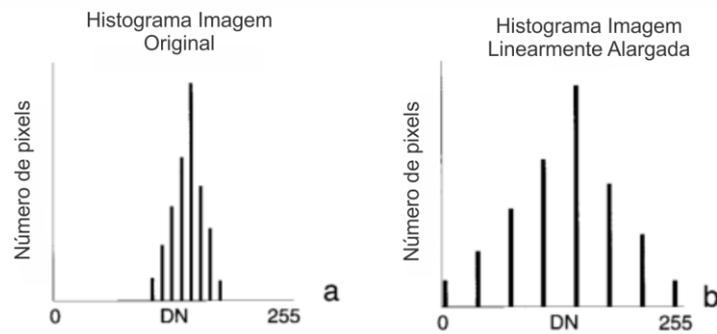
Figura 5 - Exemplo de alargamento de contraste; (a) Imagem original; (b) Imagem alargada



Fonte: PRASAD, [s. d.]

Existem diversas abordagens para realizar essa operação, utilizando funções de transformações que convertem os valores da imagem original em valores correspondentes na imagem de saída por meio de funções lineares ou não lineares. No alargamento linear de contraste, os valores de intensidade da imagem original são expandidos uniformemente para preencher a escala total do dispositivo de saída (Figura 6). Assim, em um sistema de 8 bits, a imagem pode ser exibida em um máximo de 256 níveis de cinza, redimensionando-se a imagem para a faixa de 0 a 255 na imagem de saída (PRASAD, [s. d.]).

Figura 6 - Histogramas das imagens da Figura 5; (a) histograma da imagem original; (b) histograma da imagem com alargamento de contraste linear.



Fonte: adaptado de PRASAD, [s. d.]

No alargamento não linear de contraste, pode-se melhorar os valores de intensidade dos pixels com base na frequência de cada pixel na imagem original, através da técnica de equalização de histogramas; ou com base em diferentes funções lineares, aprimorando-se os valores de intensidade em diferentes faixas da mesma imagem, através da técnica de alargamento por pedaço; ou, ainda, com base em curvas logarítmicas, através da técnica de alargamento logarítmico ou Gaussiano (PRASAD, [s. d.]).

No presente trabalho, optou-se por desenvolver um alargamento não linear por meio do alargamento por pedaço, o que permitiu desenvolver um algoritmo genérico possibilitando a aplicação de diferentes faixas por parte do usuário da interface. Para tal, utilizou-se a formulação abaixo (DSOUZA, 2022; YOUTUBE CHANNEL ELECTRICAL & COMPUTER ENGINEERING PROJECT, 2021):

$$\text{Pixel de saída} = \begin{cases} \alpha \times r, & \text{se } 0 \leq r < r_1 \\ \beta \times (r - r_1) + w_1, & \text{se } r_1 \leq r < r_2 \\ \gamma \times (r - r_2) + w_2, & \text{se } r_2 \leq r < L - 1 \end{cases} \quad (3.6.2.1)$$

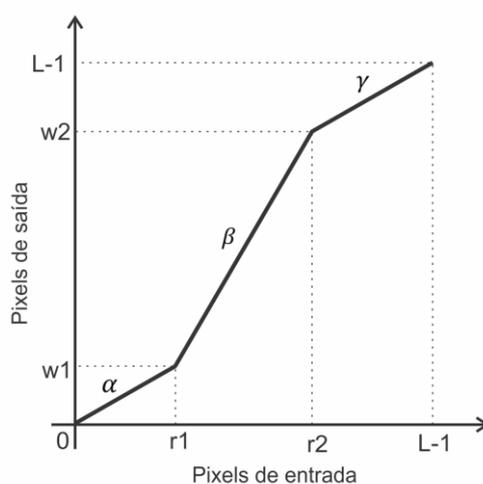
com

$$\alpha = \frac{w_1 - 0}{r_1 - 0} \quad \text{e} \quad \beta = \frac{w_2 - w_1}{r_2 - r_1} \quad \text{e} \quad \gamma = \frac{(L - 1) - w_2}{(L - 1) - r_2} \quad \begin{matrix} (3.6.2.2, 3.6.2.3 \\ \text{e } 3.6.2.4) \end{matrix}$$

em que r é o valor da intensidade do pixel de entrada; w_1 e w_2 são, respectivamente, os valores mínimo e máximo para os quais desejamos alargar o contraste; r_1 e r_2 determinam a faixa de valores que deseja-se alargar; L é o número de níveis de cinza

da imagem, dado por $2^{\text{número de bits da imagem}}$; e α , β e γ são as inclinações das retas responsáveis pelo estiramento do contraste, conforme ilustrado no gráfico da Figura 7:

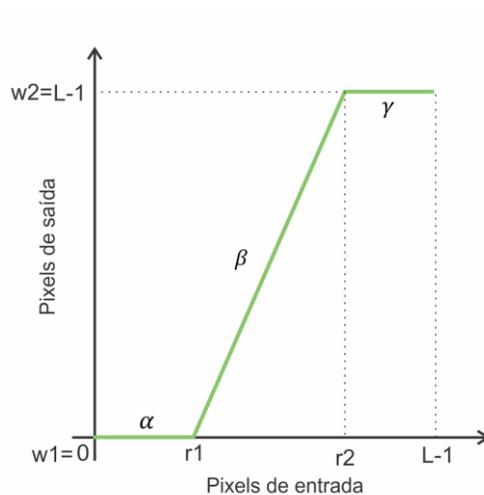
Figura 7 – Representação gráfica da função de transformação para o alargamento de contraste por pedaços



Fonte: autoria própria.

Vale ressaltar que ao escolher $w1$ e $w2$ como os valores de 0 e o valor máximo de branco presente na imagem ($L-1$), obtém-se um alargamento de contraste linear, produzindo uma imagem de maior contraste do que a original por meio do escurecimento dos níveis abaixo da função de transformação com angulação β e do clareamento daqueles acima dessa função (Figura 8):

Figura 8 - Representação gráfica da função de transformação para o alargamento de contraste com $w1 = 0$ e $w2 = L-1$



Fonte: autoria própria.

Portanto, o alargamento de contraste permite aprimorar uma imagem caso sua distribuição dos níveis de cinza esteja distribuída em uma faixa de valores de intensidades menor, através da expansão do número de níveis de cinza para uma faixa mais ampla.

4 METODOLOGIA

Para o desenvolvimento deste trabalho, foi implementado um algoritmo em MATLAB para realização da segmentação das lesões pulmonares, juntamente com uma interface de interação.

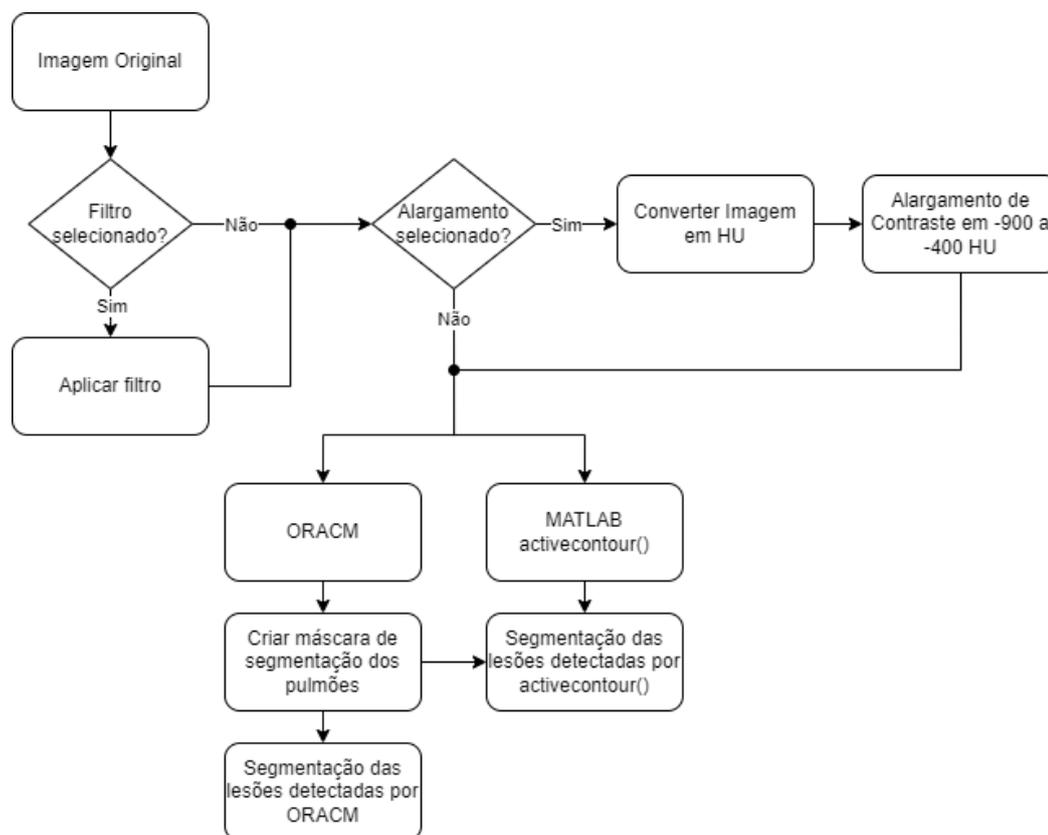
A base de dados utilizada para os testes é composta pela seleção das fatias tomográficas de pulmão de exames presentes no repositório do Hospital São Lucas da Pontifícia Universidade Católica do Rio Grande do Sul (HSL-PUCRS). Desse modo, a base de dados contém exames de pacientes que apresentaram diferentes tipos de doenças pulmonares como pneumonia, cardiomegalia, água na pleura, atelectasia, COVID-19 etc., além de tomógrafos de diferentes fabricantes como SIEMENS, GE MEDICAL SYSTEMS, Philips Medical Systems e TOSHIBA.

Especificamente, os cortes variam de 1 a 5 mm de espessura e cada exame apresenta em torno de 400 fatias. Destas, foram escolhidas as fatias que continham os pulmões, excluindo-se as restantes. Ainda, para o presente estudo foram considerados três exames completos realizados em tomógrafos da SIEMENS com cortes de 2 mm de espessura. Como na base de dados não há a descrição das patologias, sabe-se que há diferentes patologias mas não se sabe quais.

O processamento foi dividido em diversas abordagens de pré-processamento e utilizando-se as técnicas de segmentação de contornos ativos pela função integrada ao MATLAB, *activecontour()* (MATLAB ACM), que realiza a técnica de contornos ativos por *level-set sparse field*, e com o uso da técnica *online region ORACM*, desenvolvida por Talu (2013).

Assim, conforme selecionado na interface, a imagem original pode passar por um alargamento de contraste, ou ainda passar por filtros de média e mediana, antes da aplicação dos contornos ativos MATLAB ACM e ORACM. O diagrama presente na Figura 9 elucida as etapas do processamento:

Figura 9 - Diagrama do processamento realizado



Fonte: autoria própria.

Portanto, a imagem original irá passar por um processo de filtragem espacial e pelo processo de alargamento de contraste, caso estes sejam selecionados na interface. A primeira operação é realizada conforme explicado no item 3.6.1, podendo-se utilizar um filtro de média 3x3 ou um filtro de mediana 3x3.

Para a segunda operação, a imagem será convertida em valores na escala de Hounsfield, realizando-se o procedimento do alargamento de contraste linear na faixa ideal para caracterização das estruturas dos pulmões: de -500 a -900 HU (Tabela 1), utilizando-se as equações 3.6.2.1 a 3.6.2.4.

Assim, para $w1$ (Equação 3.6.2.1) foi usado o valor equivalente ao 0 em HU enquanto que para $w2$ foi usado o valor equivalente ao 4095 em HU; e $r1 = -900$ HU e $r2 = -500$ HU. O valor de 4095 é referente ao número de tons de cinza relacionado ao número de bits das imagens; como as imagens do banco de dados são de 12 bits, tem-se 2^{12} resultando em tons de cinza entre 0 e 4095. Ainda, é possível alterar as faixas de $r1$ e $r2$ e de $w1$ e $w2$ por meio da interface, permitindo realizar o alargamento de contraste por pedaço.

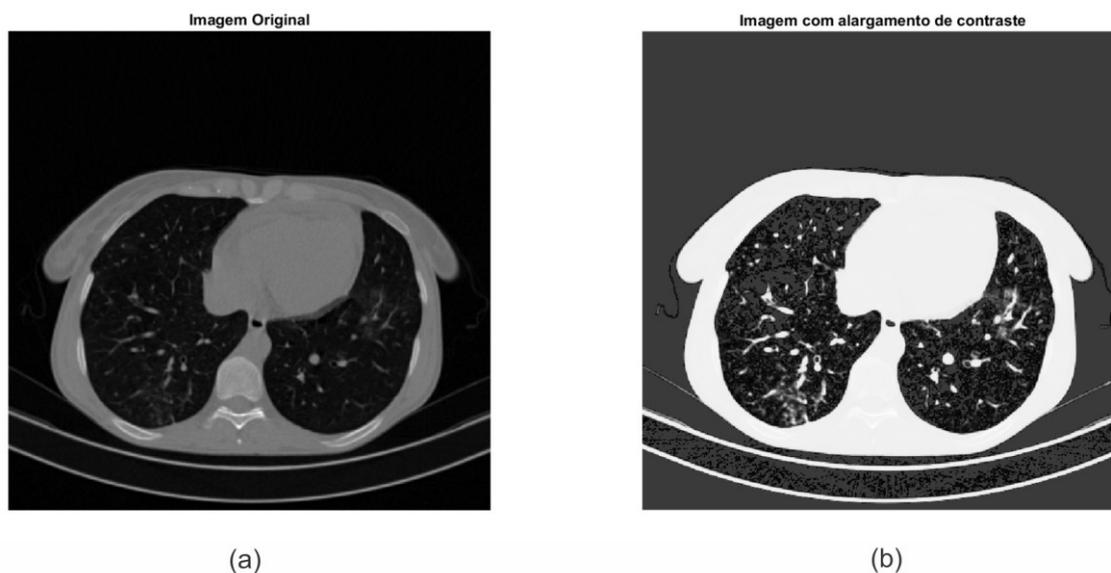
Para obter os valores equivalentes em HU de $w1$, $w2$ e das intensidades dos pixels da imagem, utilizou-se as tags DICOM *rescale intercept* (0028; 1052) e *rescale slope* (0028; 1053), que especificam a transformação linear de pixels em sua representação em disco para sua representação em memória, fazendo a conversão através da equação 4.1:

$$HU = P \cdot info.RescaleSlope + info.RecaleIntercept \quad (4.1)$$

em que HU é o valor do parâmetro em Hounsfield; e P é o valor do parâmetro a ser convertido.

A Figura 10 mostra um exemplo do efeito gerado pelo alargamento de contraste:

Figura 10 – Efeito gerado pelo processo de alargamento de contraste. (a) Imagem original; (b) Imagem com alargamento de contraste.

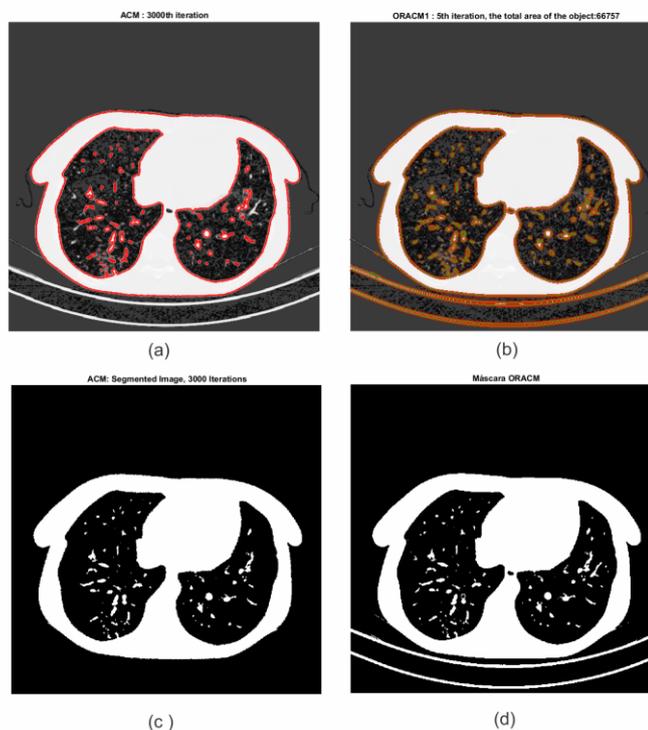


Fonte: autoria própria.

Após o pré-processamento, aplica-se as duas técnicas de segmentação, ORACM e MATLAB ACM, separadamente, obtendo-se duas máscaras com os contornos detectados pelas duas abordagens (Figura 11).

Em seguida, a região dos pulmões é selecionada de forma que as partes que não são pulmões, presentes na imagem tomográfica, sejam removidas. Para tal, utilizou-se a função *imfill()* do MATLAB que emprega semelhanças de pixels para alterar a imagem binária de acordo com pontos de localização.

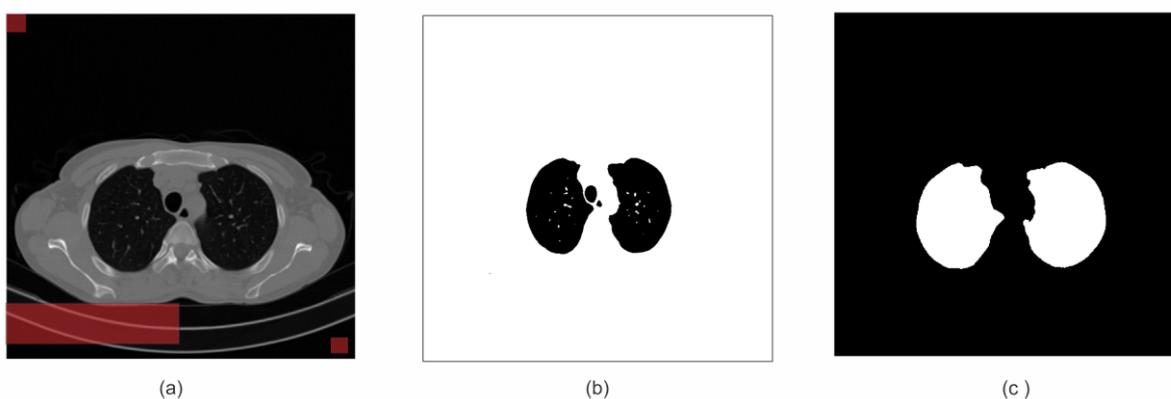
Figura 11 – Contornos detectados pelas técnicas MATLAB ACM e ORACM e suas respectivas máscaras de segmentação. (a) Contornos detectados pelo MATLAB ACM destacados em vermelho; (b) Contornos detectados pelo ORACM destacados em vermelho; (c) Máscara de segmentação gerada pelos contornos detectados pelo MATLAB ACM; (d) Máscara de segmentação gerada pelos contornos detectados pelo ORACM.



Fonte: autoria própria.

Para definição destes pontos, escolheu-se os pontos de coordenadas (1; 1); (500; 500); e a faixa de pontos com valores de x de 1 a 256 e valores de y de 445 a 480. Assim, seleccionou-se três regiões principais, conforme destaques da Figura 12 (a), que serviriam de base para a operação de preenchimento dos pixels de fundo da imagem binária de entrada.

Figura 12 – Criação da máscara de segmentação dos pulmões. (a) pontos de localização utilizados para a função *imfill()*; (b) alteração dos pixels de fundo conectados de 0 para 1 feita na imagem binária pela função *imfill()*; (c) máscara final de segmentação dos pulmões

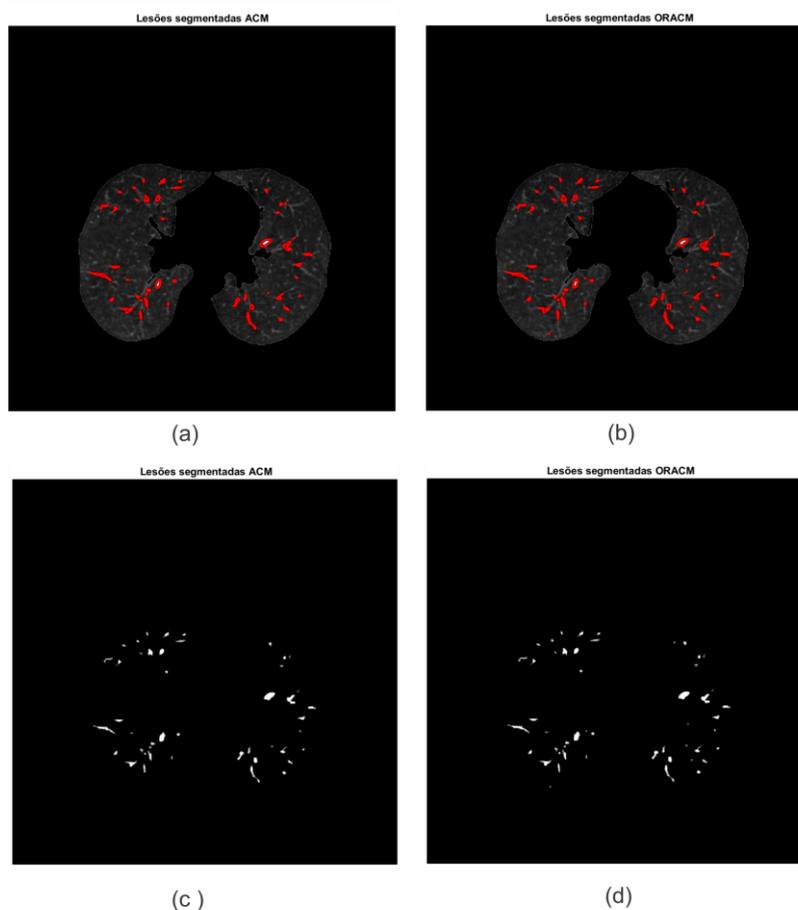


Fonte: autoria própria

Dessa forma, aplicou-se esta função na máscara retornada pela técnica ORACM de tal forma que os pixels de fundo conectados, segundo os pontos de localização, são alterados de 0 para 1 na imagem binária (Figura 12 - b), criando-se uma máscara de segmentação para isolamento dos pulmões (Figura 12 - c). Logo, se um dos pontos de localização contiver o valor da intensidade das partes que não são pulmões na imagem binária, todos os pontos conectados a esta localização serão alterados, conseguindo-se criar uma máscara que contenha somente a região dos pulmões.

Por fim, as lesões detectadas pelos contornos ativos de cada técnica são isoladas e demarcadas para melhor visualização e caracterização (Figura 13).

Figura 13 – Exemplo da extração das lesões. (a) Lesões detectadas pelo MATLAB ACM destacadas em vermelho; (b) Lesões detectadas pelo ORACM destacados em vermelho; (c) Máscara de isolamento das lesões gerada pelos contornos detectados pelo MATLAB ACM; (d) Máscara de isolamento das lesões gerada pelos contornos detectados pelo ORACM.



Fonte: autoria própria.

Para a caracterização das lesões, optou-se por comparar a área de lesões detectadas. Assim, inicia-se com a binarização da imagem que contém somente as

lesões detectadas, transformando os diferentes níveis de cinza da imagem em dois tons (branco e preto). Em seguida, conta-se o número de pixels brancos. Com isso, é possível calcular a área total de lesões detectadas por cada uma das técnicas de segmentação, através da equação 4.2:

$$\begin{aligned} \text{Área (mm)} = (\text{n}^\circ \text{ de pixels brancos}) \cdot (\text{DICOMinfo.PixelSpacing.x}) \\ \cdot (\text{DICOMinfo.PixelSpacing.y}) \end{aligned} \quad (4.1)$$

em que os termos DICOMinfo.PixelSpacing.x e DICOMinfo.PixelSpacing.y são informações presentes no cabeçalho da imagem DICOM que apresentam um valor da distância, em milímetros, entre os centros de dois pixels, tanto para x quanto para y.

Para a avaliação da detecção e segmentação das lesões pulmonares, o processamento foi dividido em sete testes que incluíram diferentes abordagens de pré-processamento:

- Bloco de Testes 01: Testes preliminares

Teste 1. Teste com alargamento de contraste e filtro de média 3x3

Teste 2. Teste com alargamento de contraste e filtro de mediana 3x3

Teste 3. Teste sem alargamento de contraste e com filtro de média 3x3

Teste 4. Teste sem alargamento de contraste e com filtro de mediana 3x3

Teste 5. Teste sem alargamento de contraste e sem filtros

- Bloco de Testes 02: Testes exame completo

Teste 1. Teste exame completo com alargamento de contraste e sem filtro

Teste 2. Teste exame completo sem alargamento de contraste e sem filtro

O primeiro bloco de exames inclui testes preliminares para análises da influência do pré-processamento, sendo selecionadas, para tal, seis fatias de forma semi-aleatória, escolhendo-se fatias que poderiam ser interessantes de se analisar a segmentação. Ao final, foram escolhidas três fatias do exame 9a_siemens_modiCASGMBH_2mm, duas do exame 10a_siemens_modiCASGMBH_2mm e uma do exame 11a_siemens_modiCASGMBH_2mm. Esta quantidade de exames foi determinada simplesmente pelo tempo de processamento necessário para realizar todos os testes dentro do cronograma do trabalho. Já nos testes do segundo bloco, foram utilizadas todas as fatias desses mesmos exames.

Com relação à interface, esta foi desenvolvida pensando em tornar o algoritmo mais interativo para que o código pudesse ser utilizado por outros usuários que não sabem utilizar o *workspace* do MATLAB e para torná-lo compartilhável. Para desenvolvê-la, foi utilizado o App Designer do MATLAB.

Através desta interface, o usuário controla o processamento selecionando os parâmetros de forma intuitiva, podendo selecionar a utilização de filtros de média e/ou mediana; realização do alargamento de contraste ou não; e a aplicação do ACM para comparação com o ORACM. Ainda, é possível selecionar uma fatia do exame ou um exame completo. Para cada fatia, pode-se realizar uma visualização rápida das imagens, bem como comparar a detecção e a área de lesões detectadas por cada técnica. Todas as imagens podem ser salvas na pasta de destino desejada pelo usuário.

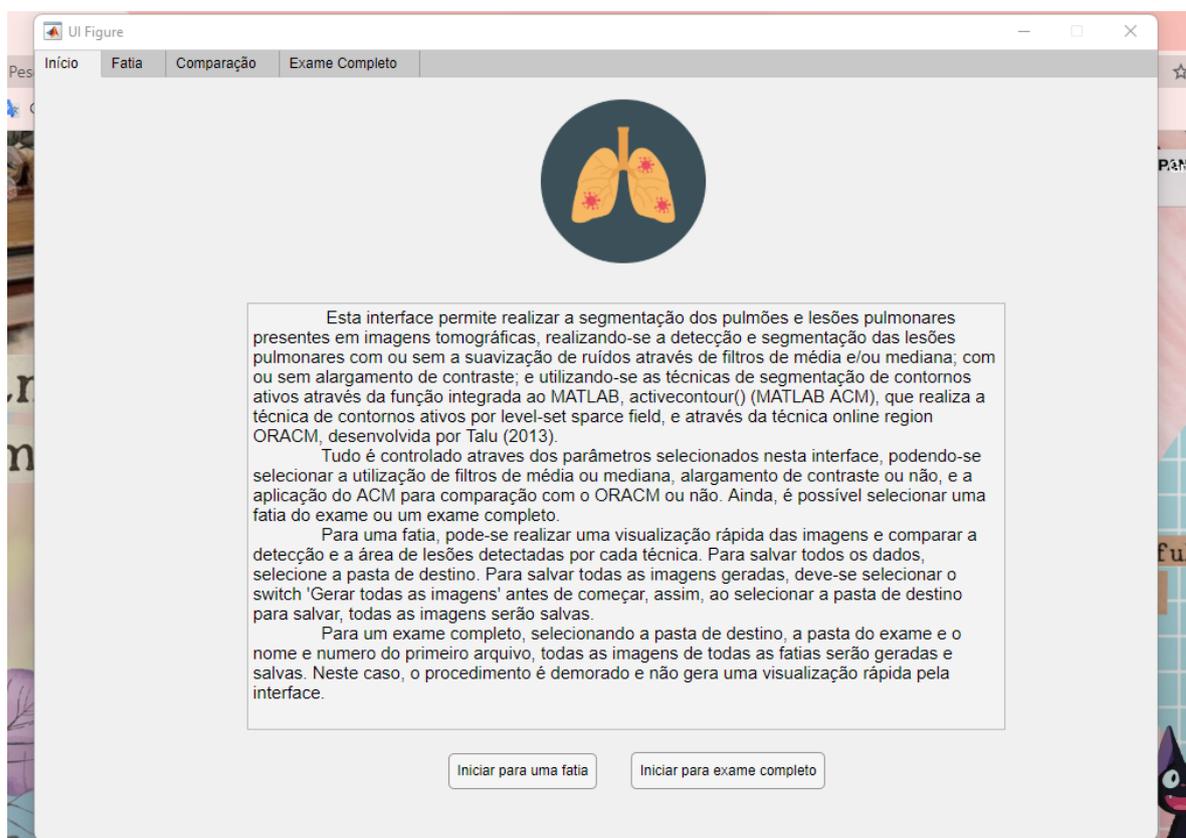
5 RESULTADOS E DISCUSSÃO

Durante esta seção, os resultados serão discutidos conforme forem sendo dispostos. Primeiramente serão mostrados os resultados obtidos para a interface. Em seguida, à fim de comparação, serão mostrados os resultados dos dois blocos dos diferentes testes que foram realizados com os dois métodos de segmentação. Para visualizar os resultados de forma ampliada, acesse: https://1drv.ms/u/s!AhJ6kJQi6q_4qd1SQmcOMjDzbyLCTQ?e=MrzqEq

5.1 Interface MATLAB

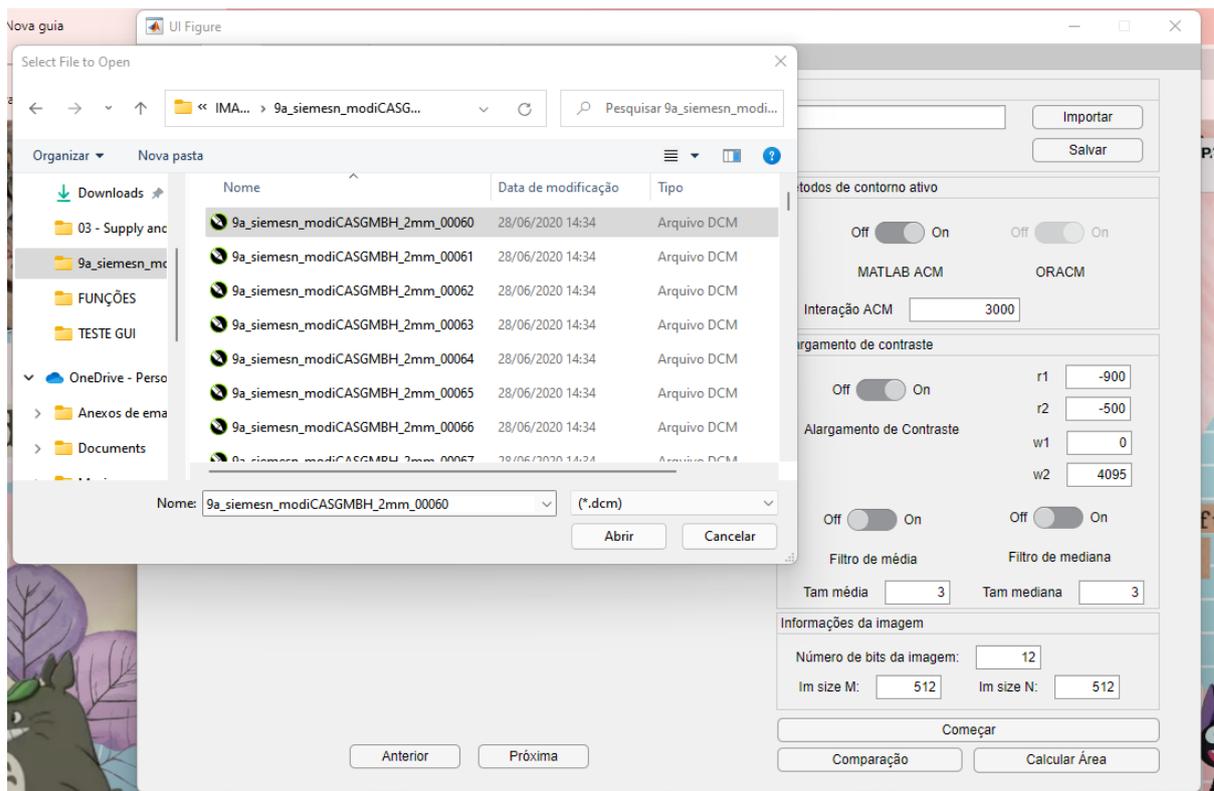
As Figuras 14 a 19 reúnem os resultados da interface confeccionada. Ela apresenta uma tela inicial com algumas informações e os botões para inicialização dos procedimentos para uma fatia ou para um exame completo (Figura 14):

Figura 14 – Tela inicial da interface MATLAB



Fonte: autoria própria.

Figura 15 - Tela de Importação da imagem



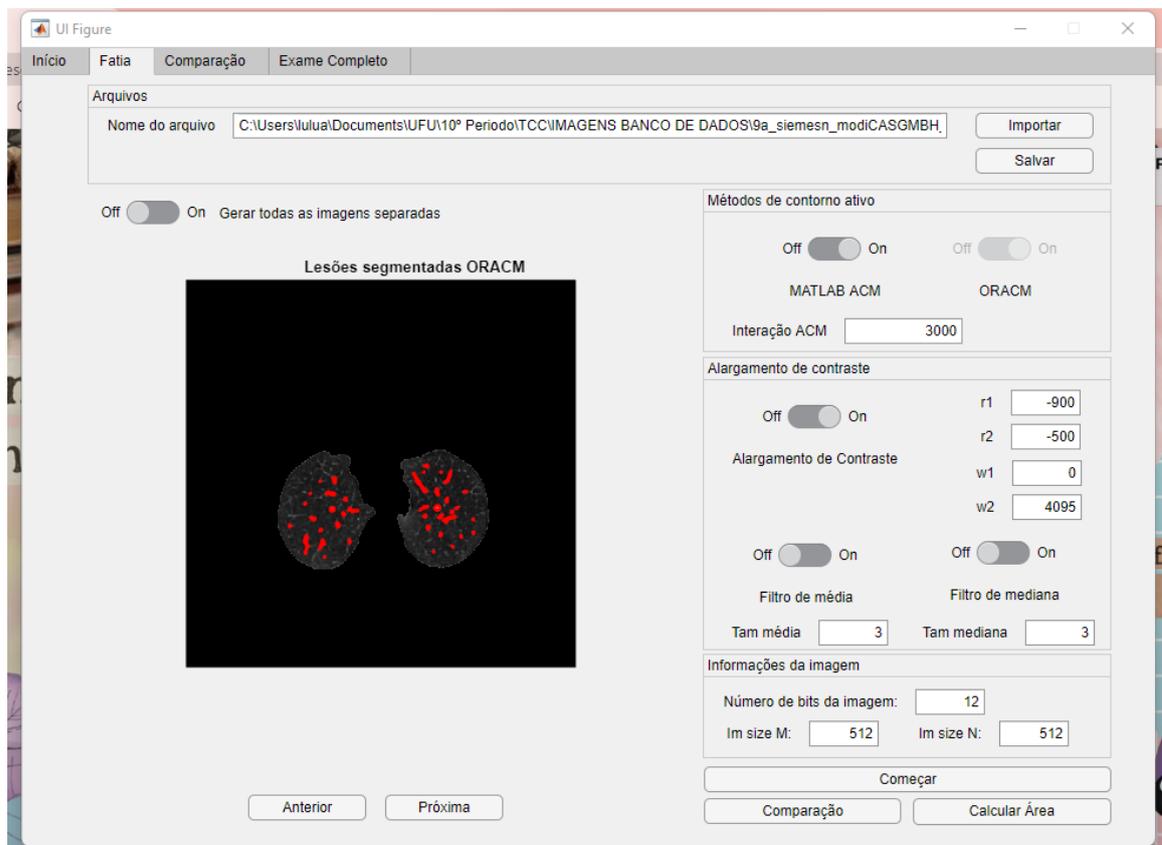
Fonte: autoria própria.

Na tela para realização do procedimento para uma fatia do exame, é possível importar o arquivo para o qual se deseja realizar a segmentação, conforme mostrado pela Figura 15, além de selecionar a utilização de filtros de média ou mediana, alargamento de contraste ou não, e a aplicação do ACM para comparação com o ORACM. Para tal, foi confeccionado o painel de controle dividido em três campos de parâmetros dos métodos de contorno ativo, alargamento de contraste e informações necessárias da imagem (Figura 16).

Para uma fatia, pode-se realizar uma visualização rápida das imagens e comparar a detecção e a área de lesões detectadas por cada técnica. Ao clicar em “Próximo” ou “Anterior”, as imagens resultantes são passadas na janela de visualização rápida.

Porém, para salvar todas as imagens deve-se selecionar o switch 'Gerar todas as imagens' antes de começar. Somente assim, ao selecionar a pasta de destino para salvar, todas as imagens serão salvas. Caso o switch esteja desligado, serão salvos todos os dados das imagens dos dois métodos e das lesões, juntamente com uma lista dos parâmetros selecionados para aquele teste.

Figura 16 – Tela Fatia para realização do procedimento para uma fatia do exame.



Fonte: autoria própria.

Ao clicar em “Calcular Área”, a área de lesões detectadas para as técnicas ativas será calculada e mostrada na janela de comparação (Figura 17). As imagens segmentadas com as lesões detectadas destacadas serão mostradas apenas ao pressionar o botão “Comparação”, na tela Fatia, ou “Comparar”, na tela comparação. Esta comparação só será realizada se a execução do MATLAB ACM estiver ativada.

Figura 17 - Tela de Comparação e apresentação das áreas de lesões detectadas

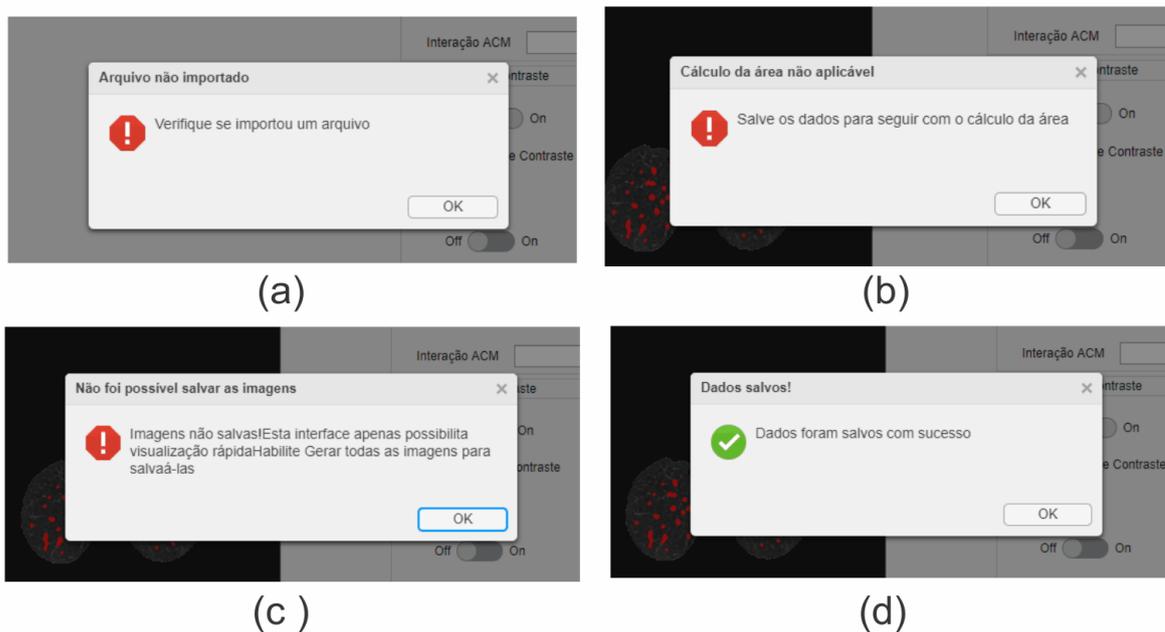


Fonte: autoria própria.

Também foram desenvolvidas caixas de avisos para caso o usuário tente começar se importar um arquivo; tente realizar a comparação sem ter ativado o switch “MATLAB ACM”; tente realizar o cálculo da área sem ter salvo os dados das imagens; tente salvar as imagens sem ativar o switch “Gerar todas as imagens”; e quando os dados e imagens foram salvos com sucesso (Figura 18).

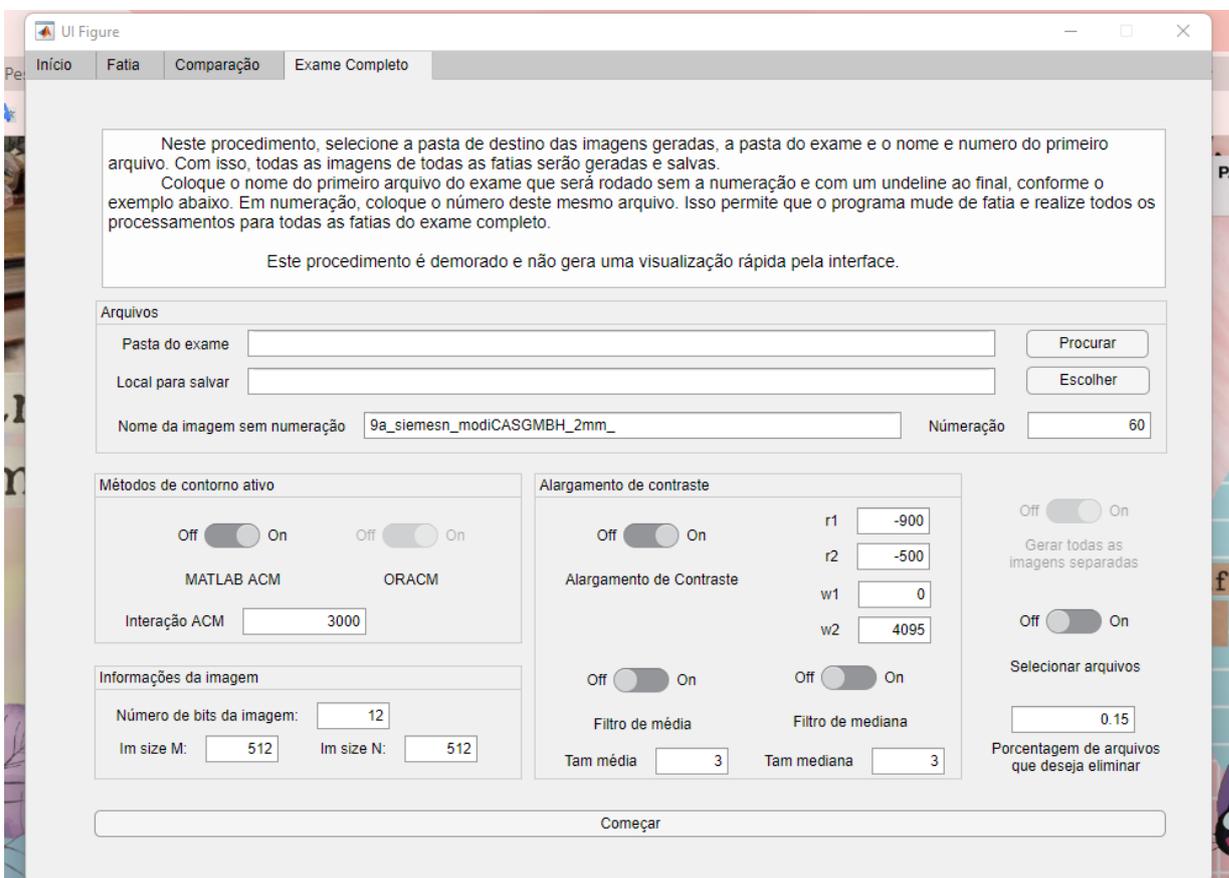
Para um exame completo, realiza-se a mesma seleção de parâmetros apenas com um controle amais: o switch “Selecionar arquivos” (Figura 19). Quando este parâmetro é ativado, o próprio programa irá realizar a eliminação de fatias do começo e do final do exame, de acordo com a porcentagem informada na caixa abaixo do switch, para selecionar as fatias de interesse.

Figura 18 – Exemplos de avisos da interface: (a) Aviso de arquivo não importado; (b) Aviso para salvar os dados necessários para o cálculo da área; (c) Aviso não foi possível salvar as imagens; (d) Aviso de dados salvos com sucesso



Fonte: autoria própria.

Figura 19 – Tela Exame Completo para realização do procedimento para todas as fatias de um exame.



Fonte: autoria própria.

Ainda, seleccionando a pasta de destino, a pasta do exame e o nome e número do primeiro arquivo, todas as imagens de todas as fatias serão geradas e salvas. Neste caso, o procedimento é demorado e não gera uma visualização rápida pela interface.

Vale ressaltar que é necessário otimizar a interface, pois na geração das imagens de visualização rápida, notou-se a abertura e fechamento de uma janela a mais gerada na aplicação do algoritmo da técnica ORACM.

5.2 Bloco de Testes 01: Testes Preliminares

5.2.1 Teste com alargamento de contraste e filtro de média 3x3

O primeiro teste foi feito aplicando-se um filtro de média 3x3 na imagem original e, em seguida, fez-se o alargamento de contraste. Após essa operação, aplicou-se os dois métodos de contorno ativo. A Tabela 2 reúne as fatias analisadas nesse teste juntamente com a área total de lesões detectadas por cada abordagem:

Tabela 2 - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste com aplicação de filtro de média 3x3 e do alargamento de contraste.

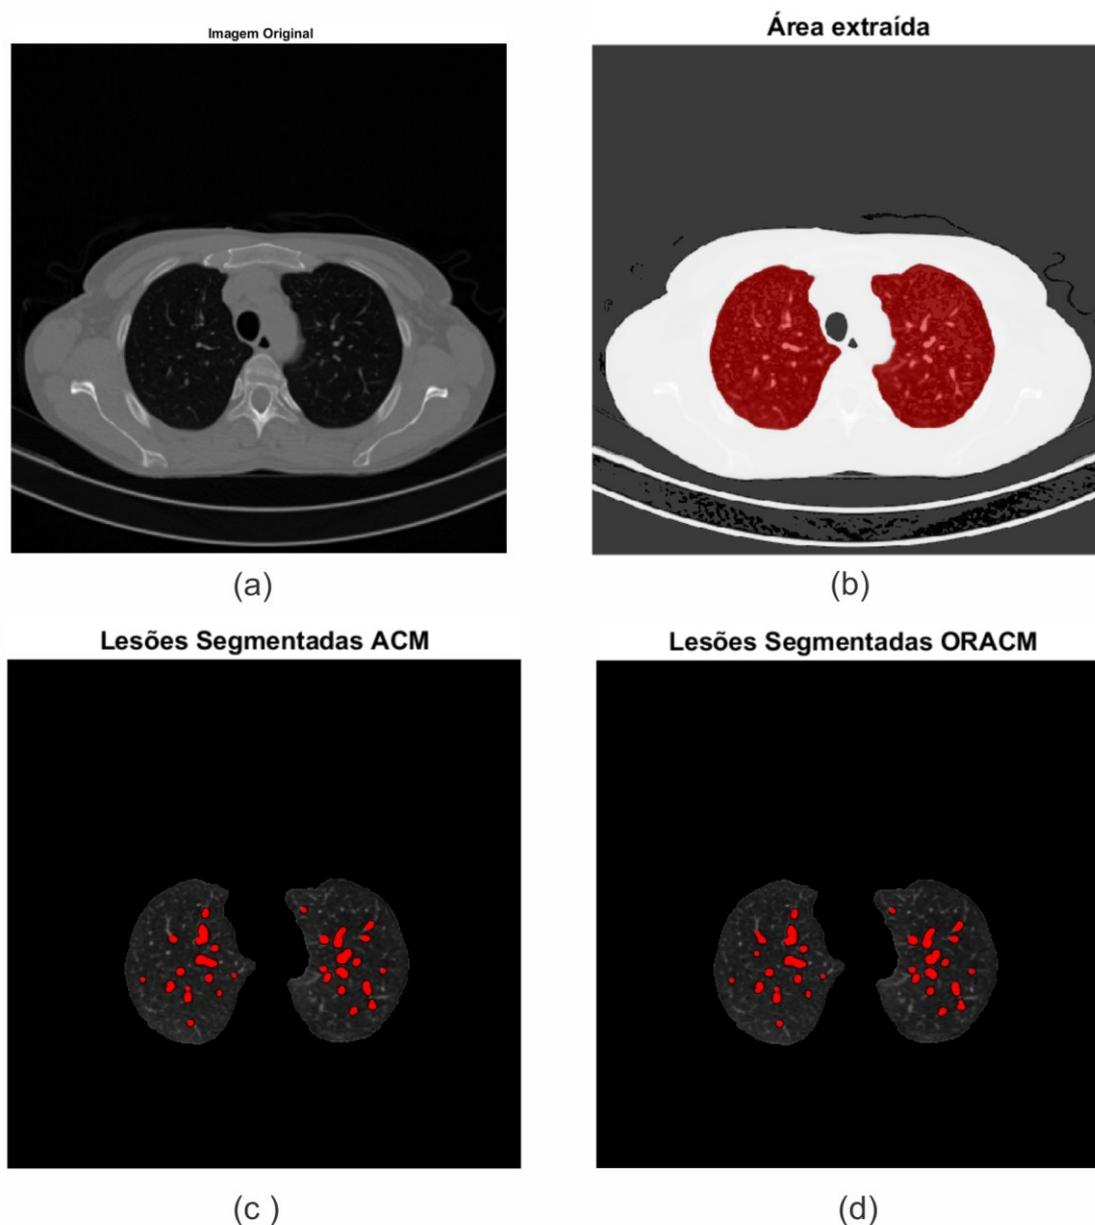
Teste com alargamento de contraste e filtro de média 3x3				
Fatia	Nº de pixels brancos		Área de lesões detectada (mm ²)	
	MATLAB ACM	ORACM	MATLAB ACM	ORACM
Exame 9a_siemens_modiCASGMBH_2mm				
00064	681	693	310.99	316.48
00127	1008	1032	460.33	471.29
00191	2122	2239	969.08	1022.50
Exame 10a_siemens_modiCASGMBH_2mm				
00068	4138	327	2918.70	230.65
00199	1573	1695	1109.50	1195.50
Exame 11a_siemens_modiCASGMBH_2mm				
00071	821	33	782.97	31.47

Fonte: autoria própria.

A área detectada pelas duas técnicas foi similar na maioria das fatias testadas, porém, na fatia 00068 do exame 10a_siemens_modiCASGMBH_2mm, a técnica

MATLAB ACM detectou o contorno externo dos pulmões e não detectou as lesões, gerando uma área maior e errônea (Figura 20- c). Nesta mesma fatia, a técnica ORACM conseguiu identificar lesões, conforme mostrado na Figura 20 – d.

Figura 20 - Teste com alargamento de contraste e filtro de média 3x3 para a fatia 00068 do exame 10a_siemens_modiCASGMBH_2mm. (a) Imagem original; (b) Imagem filtrada com alargamento de contraste com área dos pulmões que foi extraída destacada em vermelho; (c) Detecção realizada pelo método MATLAB ACM destacada em vermelho; (d) Detecção realizada pelo método ORACM destacada em vermelho.



Fonte: autoria própria.

A Figura 21 mostra os resultados obtidos para a fatia 00064 do exame 9a_siemens_modiCASGMBH_2mm. É possível avaliar de forma qualitativa (visual) que as duas técnicas detectaram uma quantidade de lesões similar (MATLAB ACM:

310.99mm² e ORACM: 316.48 mm²), entretanto, não conseguiram detectar todas as lesões presentes na imagem original.

Além disso, a fatia 00071 do exame 11a_siemens_modiCASGMBH_2mm (destacado em vermelho na Tabela 2) apresentou erro na extração da área do pulmão (Figura 22 - a), impedindo a adequada detecção e caracterização das lesões.

Figura 21 - Teste com alargamento de contraste e filtro de média 3x3 para a fatia 00064 do exame 9a_siemens_modiCASGMBH_2mm. (a) Imagem original; (b) Imagem filtrada com alargamento de contraste com área dos pulmões que foi extraída destacada em vermelho; (c) Detecção realizada pelo método MATLAB ACM destacada em vermelho; (d) Detecção realizada pelo método ORACM destacada em vermelho.

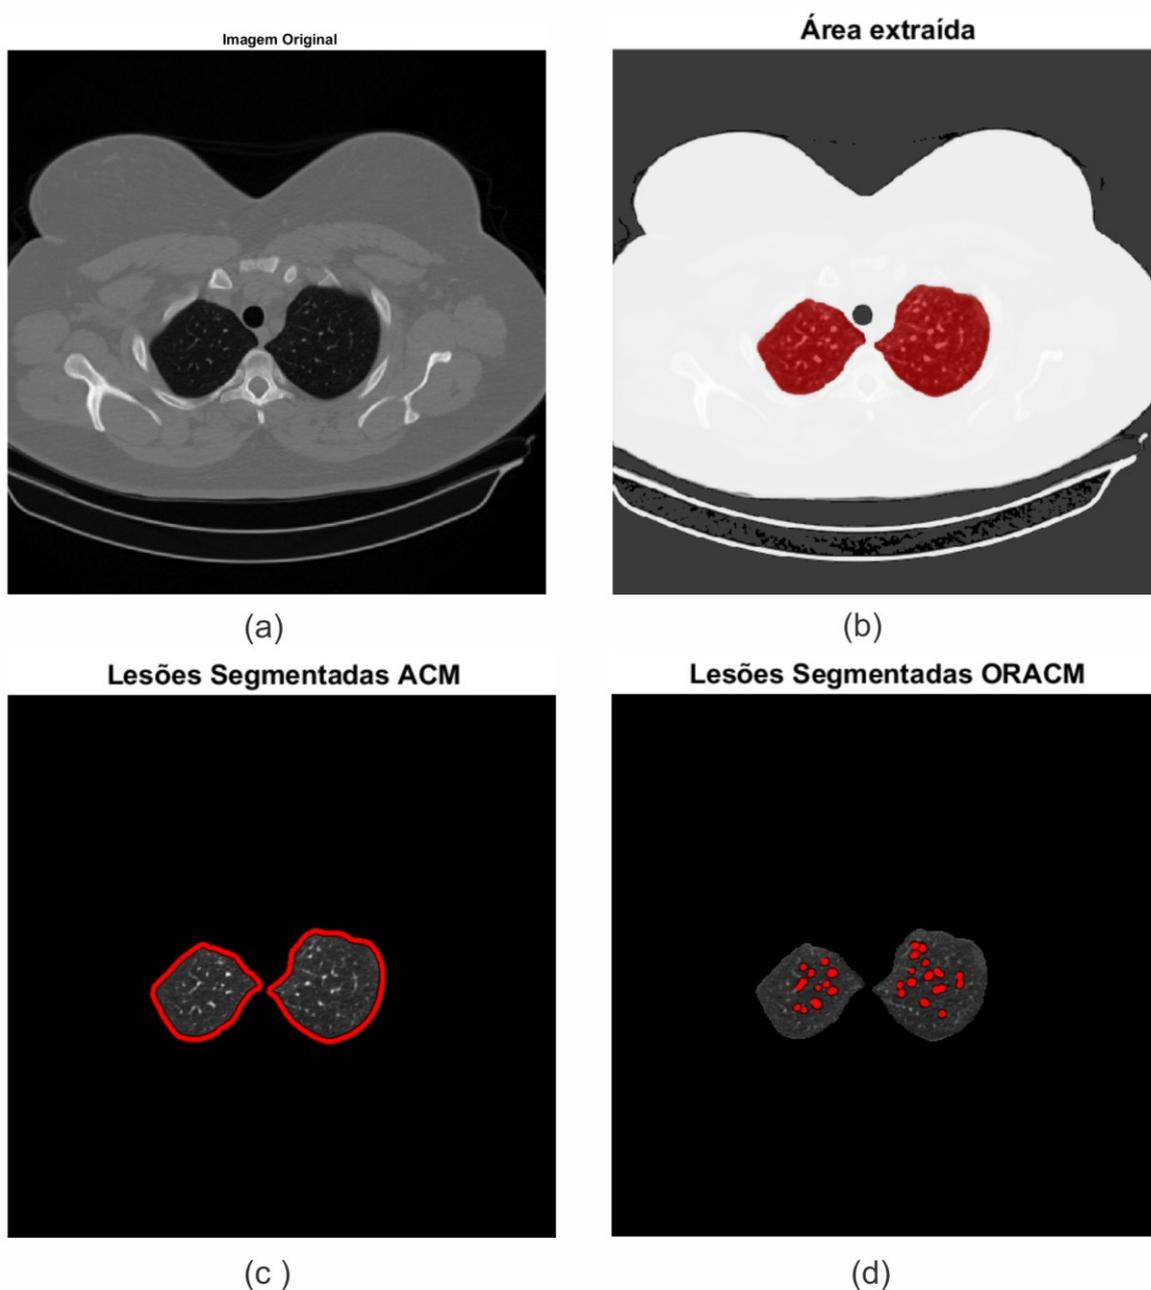
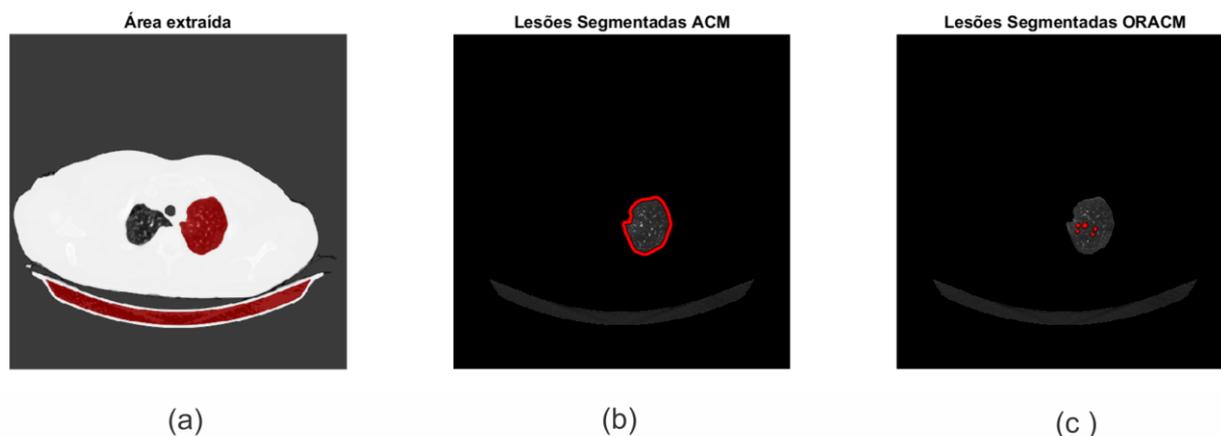


Figura 22 - Teste com alargamento de contraste e filtro de média 3x3 para a fatia 00071 do exame 11a_siemens_modiCASGMBH_2mm. (a) Imagem filtrada com alargamento de contraste com área dos pulmões que foi extraída destacada em vermelho; (b) Detecção realizada pelo método MATLAB ACM destacada em vermelho; (c) Detecção realizada pelo método ORACM destacada em vermelho.



Fonte: autoria própria.

5.2.2 Teste com alargamento de contraste e filtro de mediana 3x3

O segundo teste foi feito da mesma maneira, aplicando-se um filtro de mediana 3x3 ao invés do filtro de média. A Tabela 3 reúne as fatias analisadas nesse teste juntamente com a área total de lesões detectadas:

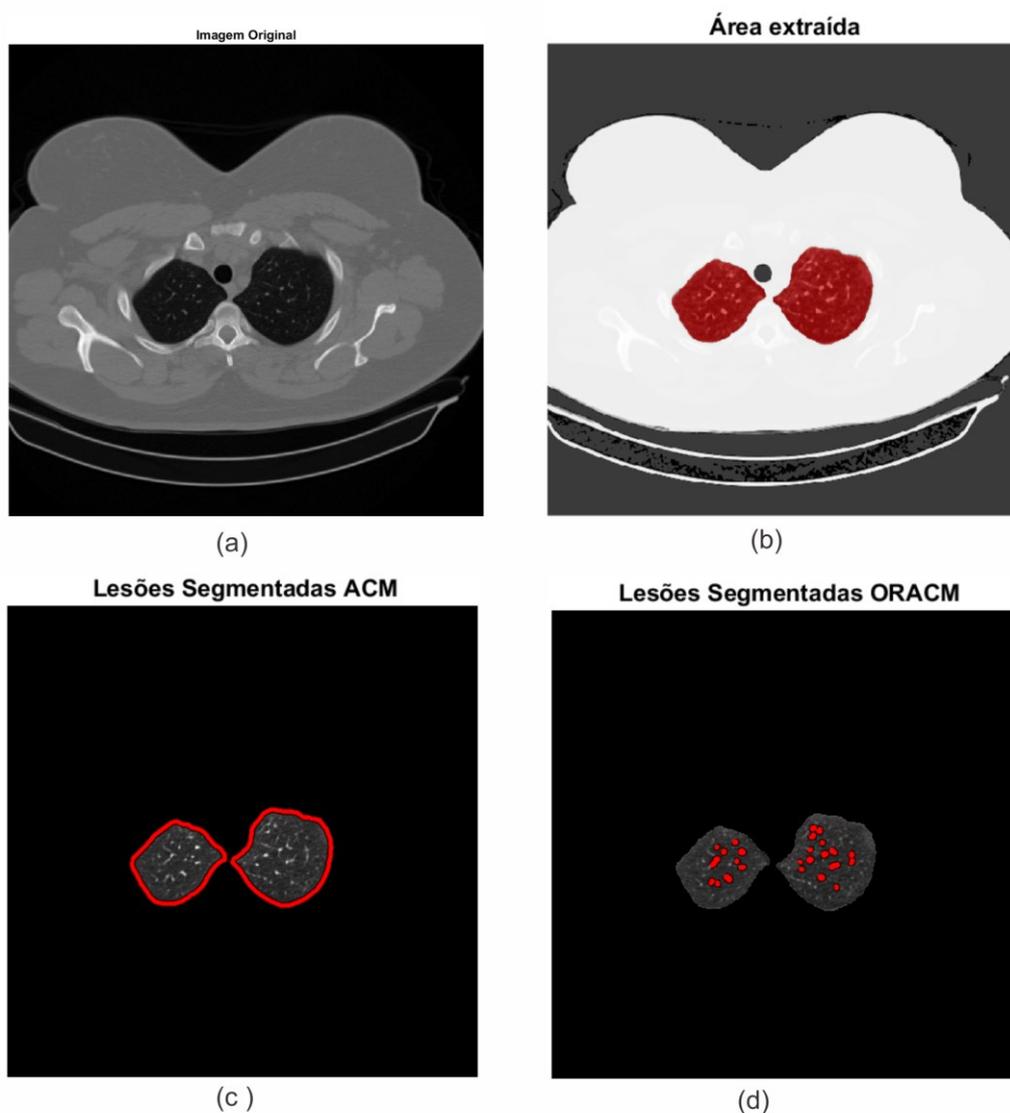
Tabela 3 - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste com aplicação de filtro de mediana 3x3 e do alargamento de contraste.

Teste com alargamento de contraste e filtro de mediana 3x3				
Fatia	Nº de pixels brancos		Área de lesões detectada (mm ²)	
	MATLAB ACM	ORACM	MATLAB ACM	ORACM
Exame 9a_siemens_modiCASGMBH_2mm				
00064	645	666	294.56	304.15
00127	1001	1033	457.14	471.75
00191	2057	2148	939.39	980.95
Exame 10a_siemens_modiCASGMBH_2mm				
00068	3565	262	2514.50	184.80
00199	1406	1538	991.70	1084.80
Exame 11a_siemens_modiCASGMBH_2mm				
00071	1488	39	1419.10	37.19

Fonte: autoria própria.

Da mesma maneira que no filtro de média, a área detectada pelas duas técnicas foi similar na maioria das fatias testadas, porém, na fatia 00068 do exame 10a_siemens_modiCASGMBH_2mm, a técnica MATLAB ACM detectou o contorno externo dos pulmões e não detectou as lesões, gerando uma área maior e errônea (Figura 23 - c). Nesta mesma fatia, a técnica ORACM conseguiu identificar lesões, conforme mostrado na Figura 23 – d. Ainda, ORACM conseguiu detectar um pouco mais de lesões do que a MATLAB ACM conforme observado pelas diferenças entre as áreas calculadas.

Figura 23 - Teste com alargamento de contraste e filtro de mediana 3x3 para a fatia 00068 do exame 10a_siemens_modiCASGMBH_2mm. (a) Imagem original; (b) Imagem filtrada com alargamento de contraste com área dos pulmões que foi extraída destacada em vermelho; (c) Detecção realizada pelo método MATLAB ACM destacada em vermelho; (d) Detecção realizada pelo método ORACM destacada em vermelho.

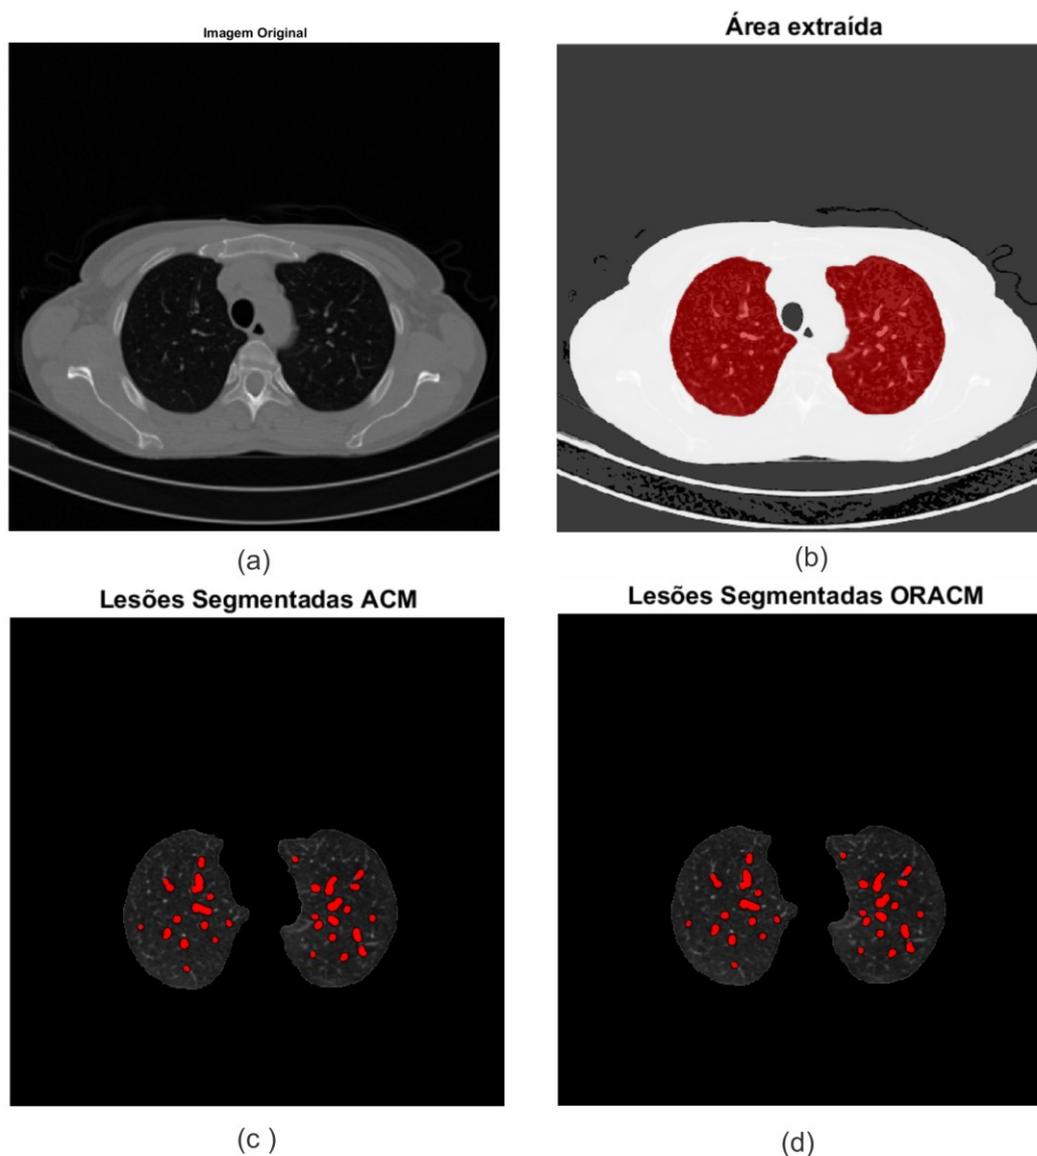


Fonte: autoria própria.

A Figura 24 mostra os resultados obtidos, neste caso, para a fatia 00064 do exame 9a_siemens_modiCASGMBH_2mm. É possível avaliar de forma qualitativa que as duas técnicas detectaram uma quantidade de lesões similar, entretanto, não conseguiram detectar todas as lesões presentes na imagem original.

Comparando-se as áreas calculadas nos dois testes, é possível verificar que na maioria dos casos o filtro de média 3x3 obteve melhores resultados que o filtro de mediana, pois permitiu que as técnicas detectassem mais lesões.

Figura 24 - Teste com alargamento de contraste e filtro de mediana 3x3 para a fatia 00064 do exame 9a_siemens_modiCASGMBH_2mm. (a) Imagem original; (b) Imagem filtrada com alargamento de contraste com área dos pulmões que foi extraída destacada em vermelho; (c) Detecção realizada pelo método MATLAB ACM destacada em vermelho; (d) Detecção realizada pelo método ORACM destacada em vermelho.



Fonte: autoria própria.

5.2.3 Teste sem alargamento de contraste e com filtro de média 3x3

O terceiro teste, similar ao primeiro, foi feito aplicando-se um filtro de média 3x3 na imagem original, porém sem aplicação do alargamento de contraste. Assim, os métodos de contorno ativo foram aplicados na imagem filtrada. A Tabela 4, reúne as fatias analisadas nesse teste juntamente com a área total de lesões detectadas por cada abordagem:

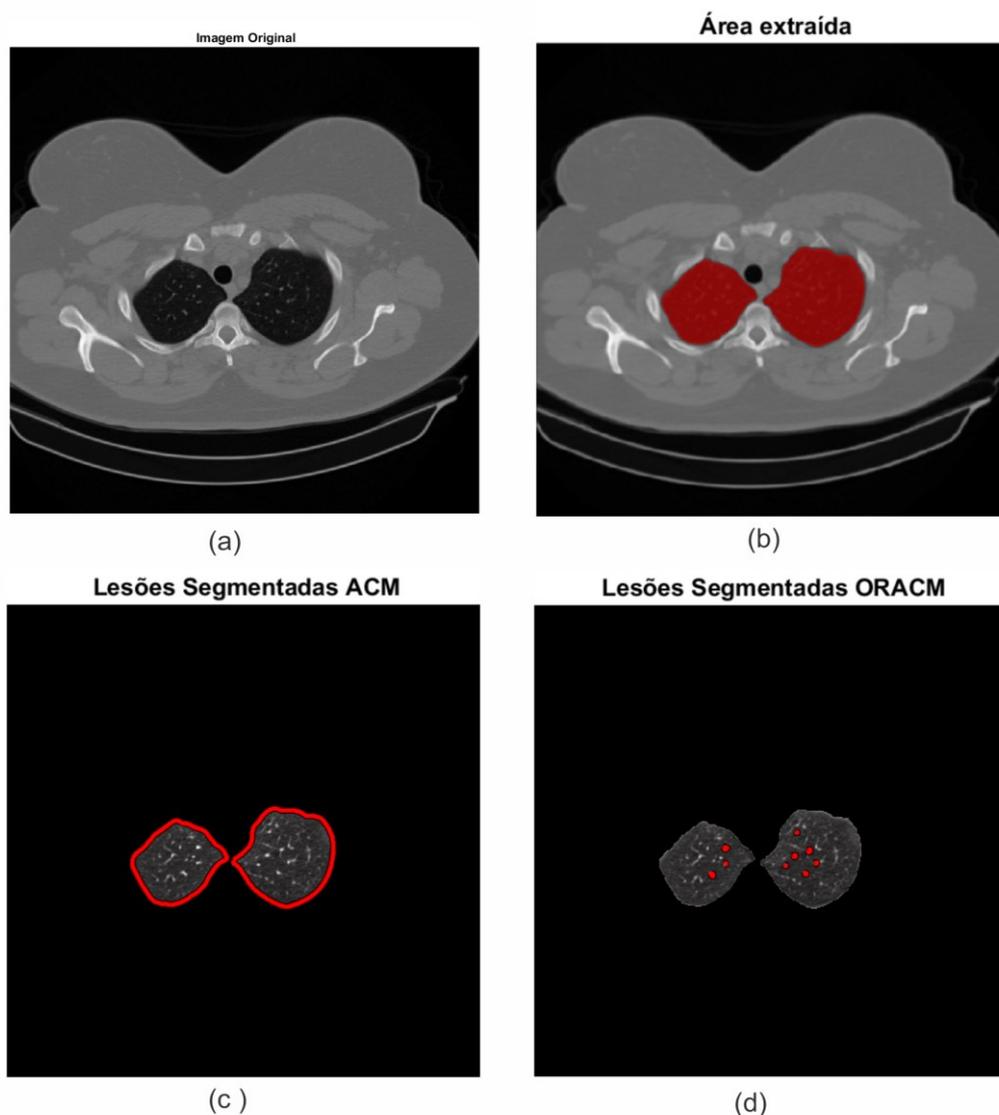
Tabela 4 - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste com aplicação de filtro de média 3x3 sem alargamento de contraste.

Teste sem alargamento de contraste e com filtro de média 3x3				
Fatia	Nº de pixels brancos		Área de lesões detectada (mm ²)	
	MATLAB ACM	ORACM	MATLAB ACM	ORACM
Exame 9a_siemens_modiCASGMBH_2mm				
00064	185	195	84.49	89.05
00127	335	358	152.99	163.49
00191	837	918	382.24	419.23
Exame 10a_siemens_modiCASGMBH_2mm				
00068	14125	67	962.90	47.26
00199	627	688	442.25	485.27
Exame 11a_siemens_modiCASGMBH_2mm				
00071	7742	11	7383.30	10.49

Fonte: autoria própria.

A área detectada pelas duas técnicas foi similar na maioria das fatias testadas, porém, na fatia 00068 do exame 10a_siemens_modiCASGMBH_2mm, a técnica MATLAB ACM detectou o contorno externo dos pulmões e não detectou as lesões, gerando uma área maior e errônea (Figura 25 - c). Nesta mesma fatia, a técnica ORACM conseguiu identificar lesões, conforme mostrado na Figura 25 – d. Ainda, ORACM conseguiu detectar mais de lesões do que a MATLAB ACM, conforme observado pelas diferenças entre as áreas calculadas. Estas diferenças foram maiores do que no teste com o alargamento de contraste.

Figura 25 - Teste sem alargamento de contraste e com filtro de média 3x3 para a fatia 00068 do exame 10a_siemens_modiCASGMBH_2mm. (a) Imagem original; (b) Imagem filtrada com alargamento de contraste com área dos pulmões que foi extraída destacada em vermelho; (c) Detecção realizada pelo método MATLAB ACM destacada em vermelho; (d) Detecção realizada pelo método ORACM destacada em vermelho.



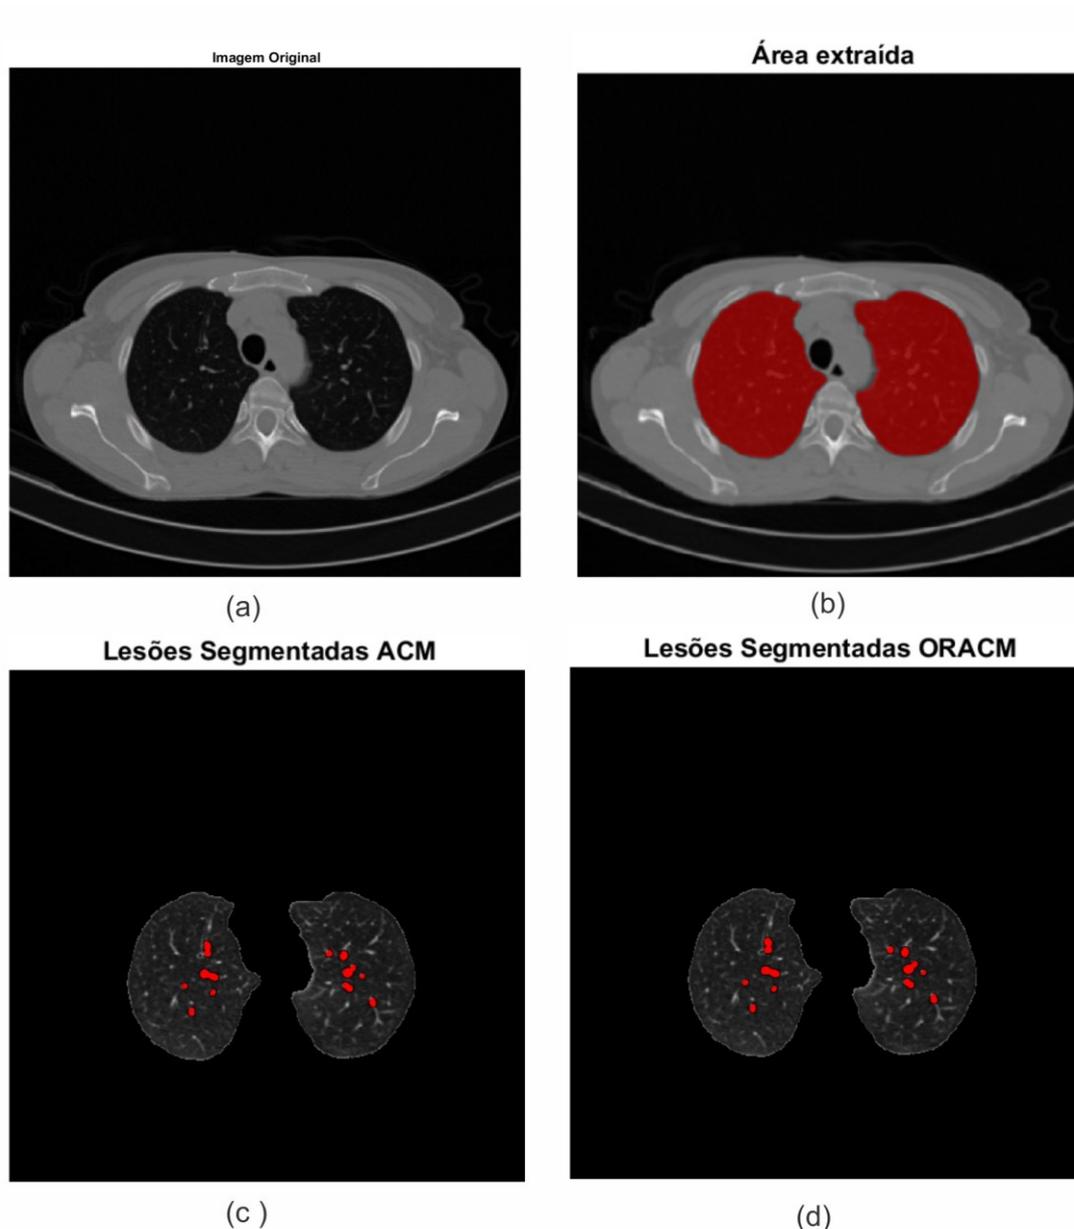
Fonte: autoria própria.

Além disso, na fatia 00071 do exame 11a_siemens_modiCASGMBH_2mm (destacado em vermelho na Tabela 4), a técnica MATLAB ACM detectou o contorno externo dos pulmões sem detectar as lesões, gerando uma área maior e errônea (Figura 26 - c). Nesta mesma fatia, a técnica ORACM conseguiu identificar apenas duas lesões, conforme mostrado na Figura 26, também contabilizando uma área errônea.

A Figura 27 mostra os resultados obtidos para a fatia 00064 do exame 9a_siemens_modiCASGMBH_2mm. É possível avaliar de forma qualitativa que as

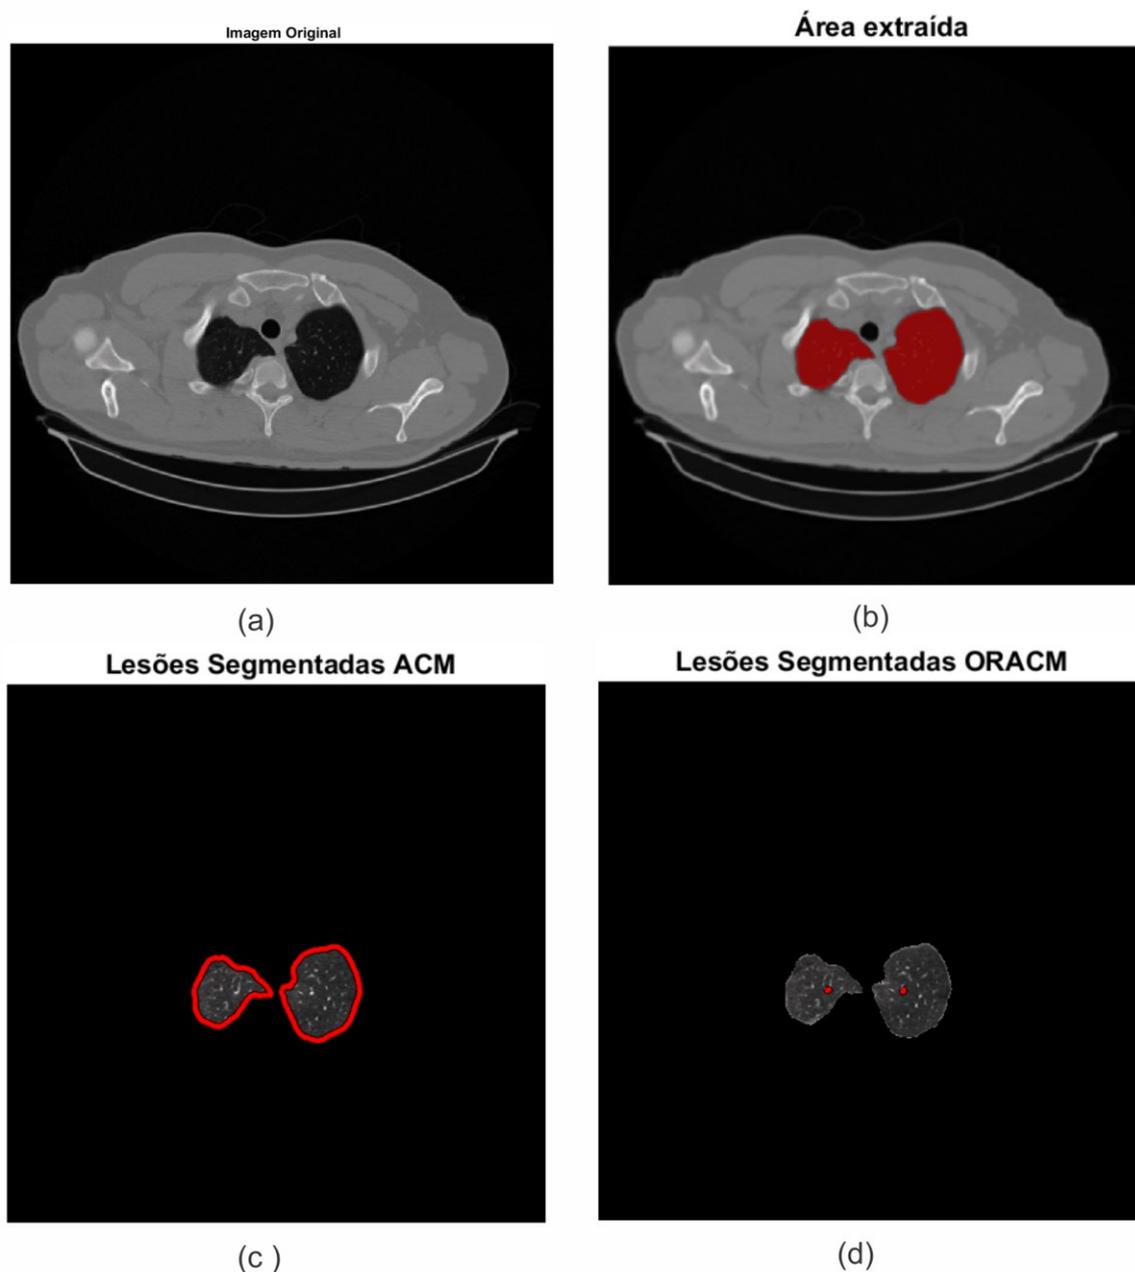
duas técnicas detectaram uma quantidade de lesões similar, entretanto, não conseguiram detectar todas as lesões presentes na imagem original.

Figura 26 - Teste sem alargamento de contraste e com filtro de média 3x3 para a fatia 00064 do exame 9a_siemens_modiCASGMBH_2mm. (a) Imagem original; (b) Imagem filtrada com alargamento de contraste com área dos pulmões que foi extraída destacada em vermelho; (c) Detecção realizada pelo método MATLAB ACM destacada em vermelho; (d) Detecção realizada pelo método ORACM destacada em vermelho.



Fonte: autoria própria.

Figura 27 - Teste sem alargamento de contraste e com filtro de média 3x3 para a fatia 00071 do exame 11a_siemens_modiCASGMBH_2mm. (a) Imagem original; (b) Imagem filtrada com alargamento de contraste com área dos pulmões que foi extraída destacada em vermelho; (c) Detecção realizada pelo método MATLAB ACM destacada em vermelho; (d) Detecção realizada pelo método ORACM destacada em vermelho.



Fonte: autoria própria.

Vale ressaltar que, comparando-se com o primeiro teste, os dois métodos conseguem identificar mais lesões com a aplicação do alargamento de contraste, como é possível observar de forma visual pelas Figura 20 e 25 e Figura 21 e Figura 26, assim como de forma quantitativa por meio das áreas de lesões detectadas mostradas nas Tabela 2 e Tabela 4.

5.2.4 Teste sem alargamento de contraste e com filtro de mediana 3x3

Da mesma forma, o teste seguinte avaliou a detecção das lesões pelos métodos de contorno ativo sem a aplicação do alargamento de contraste, aplicando-se o filtro de mediana. A Tabela 5 reúne os resultados das fatias analisadas:

Tabela 5 - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste com aplicação de filtro de mediana 3x3 sem alargamento de contraste.

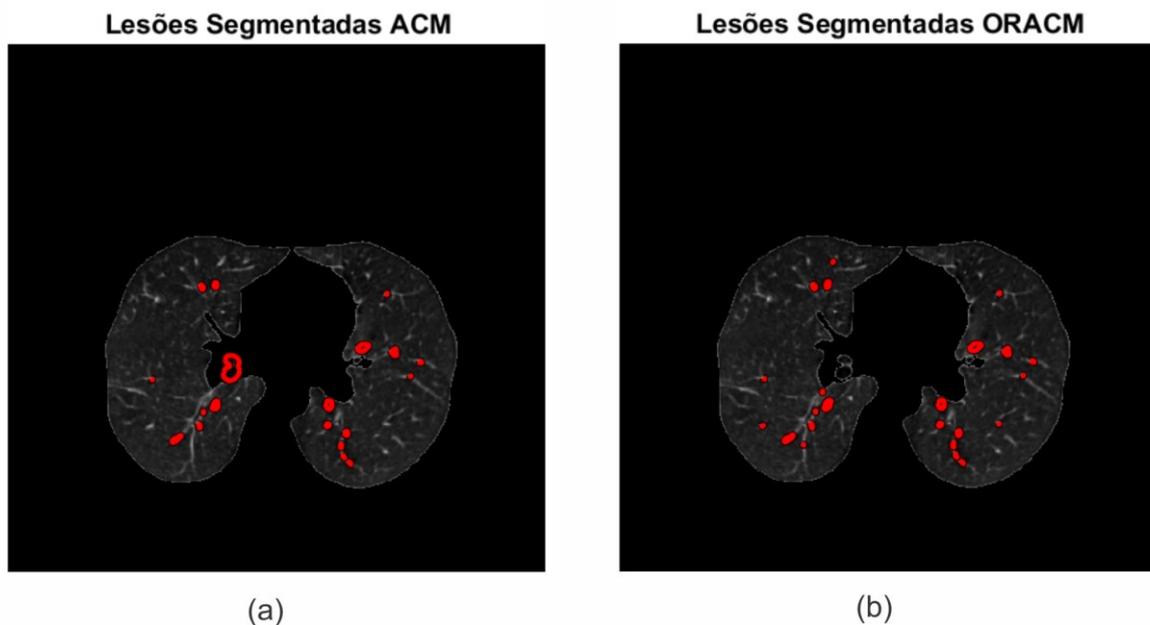
Teste sem alargamento de contraste e com filtro de mediana 3x3				
Fatia	Nº de pixels brancos		Área de lesões detectada (mm ²)	
	MATLAB ACM	ORACM	MATLAB ACM	ORACM
Exame 9a_siemens_modiCASGMBH_2mm				
00064	190	200	86.77	91.34
00127	658	401	300.560	183.13
00191	895	938	408.73	428.37
Exame 10a_siemens_modiCASGMBH_2mm				
00068	14193	48	10011.00	33.86
00199	643	698	453.53	492.33
Exame 11a_siemens_modiCASGMBH_2mm				
00071	7772	0	7412.00	0

Fonte: autoria própria.

A área detectada pelas duas técnicas foi similar na maioria das fatias testadas, porém, três fatias (destaques em vermelho na Tabela 5) apresentaram erros de detecção. Na fatia 00127 do exame 9a_siemens_modiCASGMBH_2mm, a técnica MATLAB ACM detectou o contorno externo de dois vasos sanguíneos como parte das lesões, gerando uma área maior que a detectada pelo ORACM (Figura 28).

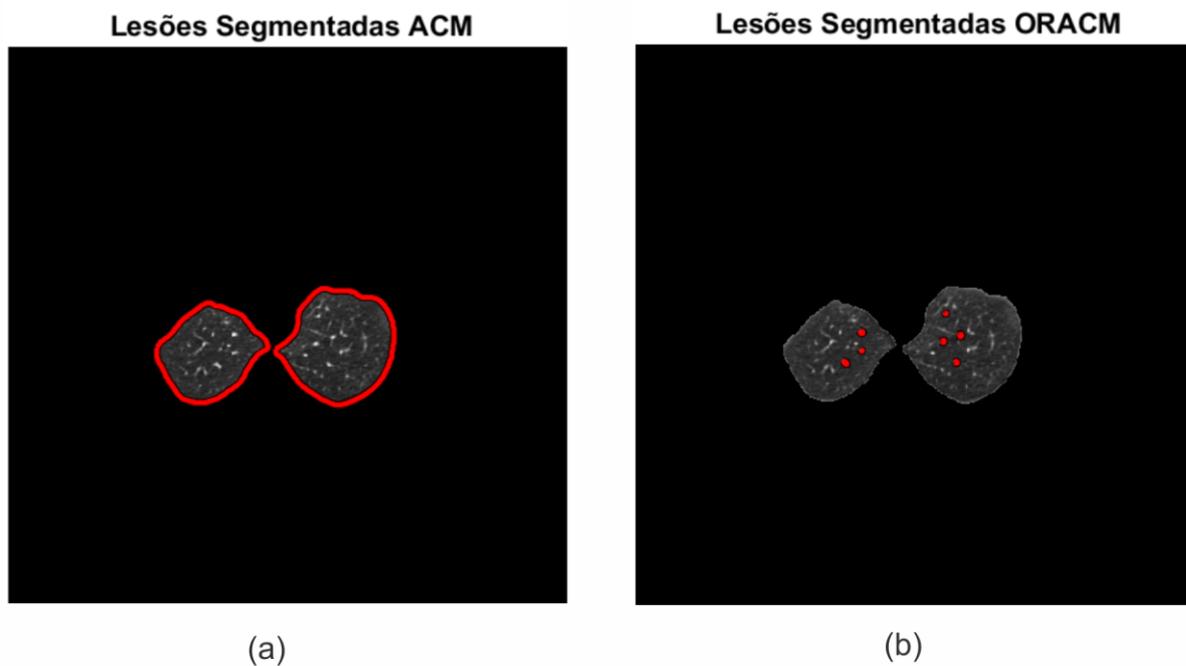
Na fatia 00068 do exame 10a_siemens_modiCASGMBH_2mm, a técnica MATLAB ACM detectou o contorno externo dos pulmões e não detectou as lesões, gerando uma área maior e errônea (Figura 29 - a). Nesta mesma fatia, a técnica ORACM conseguiu identificar lesões, conforme mostrado na Figura 29 - b. Ainda, ORACM conseguiu detectar mais lesões do que a MATLAB ACM conforme observado pelas diferenças entre as áreas calculadas. Estas diferenças foram maiores do que no teste com o alargamento de contraste.

Figura 28 - Teste sem alargamento de contraste e com filtro de mediana 3x3 para a fatia 00127 do exame 9a_siemens_modiCASGMBH_2mm. (a) Detecção realizada pelo método MATLAB ACM destacada em vermelho; (b) Detecção realizada pelo método ORACM destacada em vermelho.



Fonte: autoria própria.

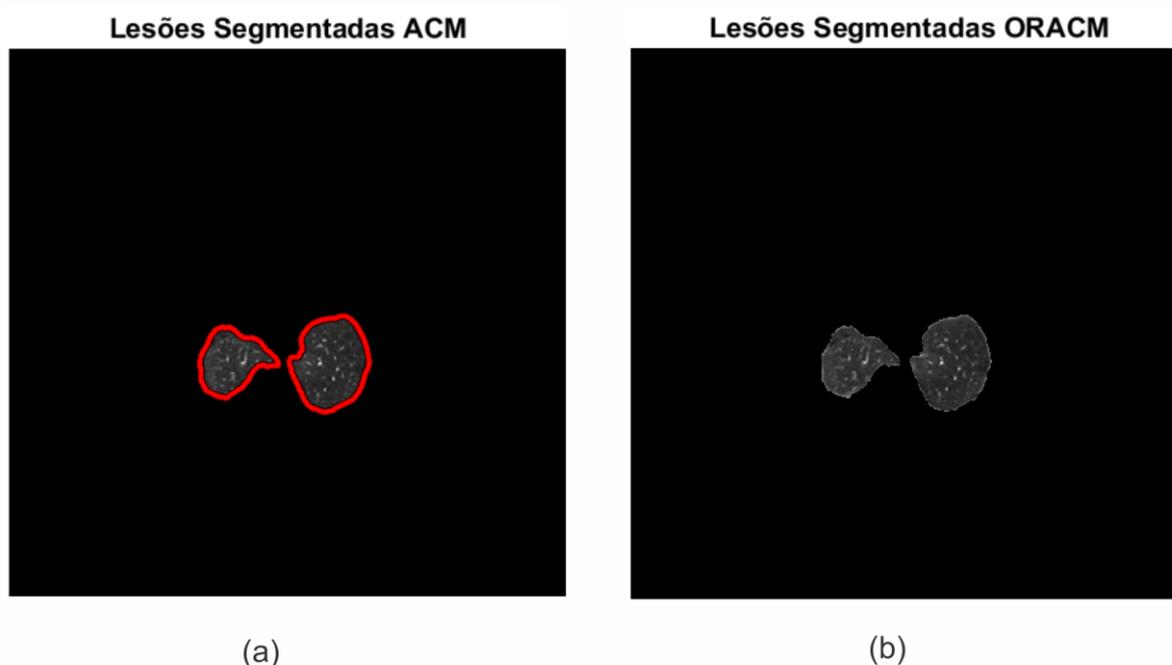
Figura 29 - Teste sem alargamento de contraste e com filtro de mediana 3x3 para a fatia 00068 do exame 10a_siemens_modiCASGMBH_2mm. (a) Detecção realizada pelo método MATLAB ACM destacada em vermelho; (b) Detecção realizada pelo método ORACM destacada em vermelho.



Fonte: autoria própria.

Na fatia 00071 do exame 11a_siemens_modiCASGMBH_2mm, a técnica MATLAB ACM detectou o contorno externo dos pulmões sem detectar as lesões, gerando uma área maior e errônea (Figura 30 - a). Nesta mesma fatia, a técnica ORACM não conseguiu detectar lesões, conforme mostrado na Figura 30 - b.

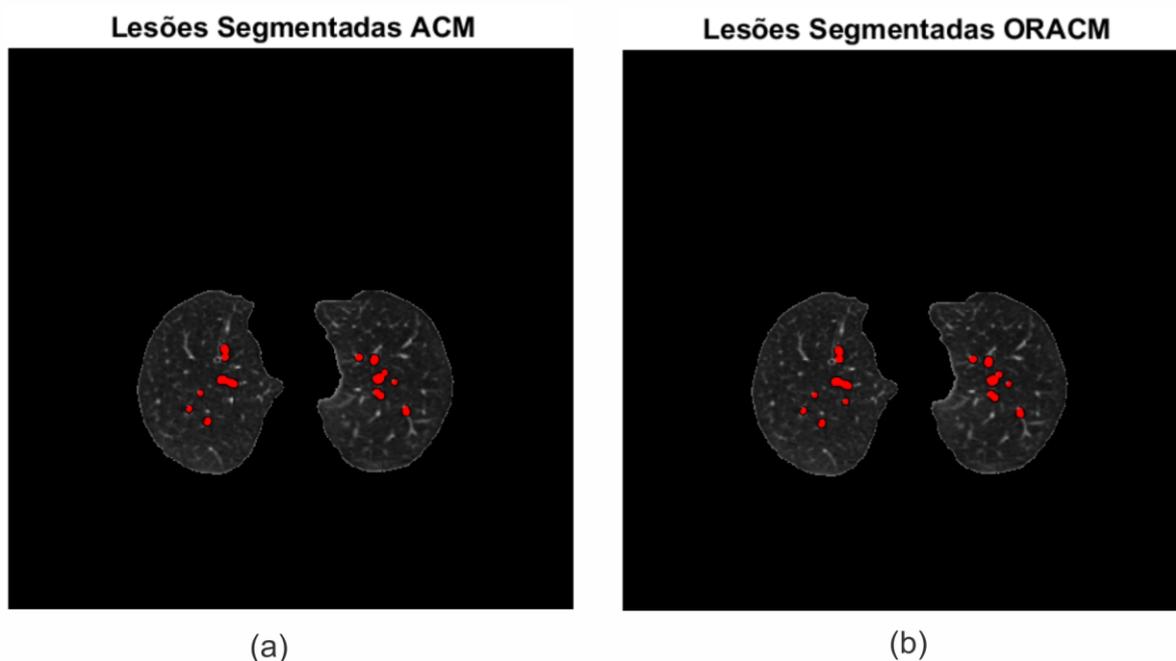
Figura 30 - Teste sem alargamento de contraste e com filtro de mediana 3x3 para a fatia 00071 do exame 11a_siemens_modiCASGMBH_2mm. (a) Detecção realizada pelo método MATLAB ACM destacada em vermelho; (b) Detecção realizada pelo método ORACM destacada em vermelho.



Fonte: autoria própria.

A Figura 31 mostra os resultados obtidos para a fatia 00064 do exame 9a_siemens_modiCASGMBH_2mm. É possível avaliar de forma qualitativa (visual) e quantitativa (por meio das áreas) que as duas técnicas detectaram uma quantidade de lesões similar, entretanto, não conseguiram detectar todas as lesões presentes na imagem original.

Figura 31 - Teste sem alargamento de contraste e com filtro de mediana 3x3 para a fatia 00064 do exame 9a_siemens_modiCASGMBH_2mm. (a) Detecção realizada pelo método MATLAB ACM destacada em vermelho; (b) Detecção realizada pelo método ORACM destacada em vermelho.



Fonte: autoria própria.

Vale ressaltar que, comparando-se com os outros testes, os dois métodos conseguem identificar mais lesões com a aplicação do alargamento de contraste, além de identificarem mais lesões quando se utiliza o filtro de média.

5.2.5 Teste sem alargamento de contraste e sem filtros

Entretanto, fez-se mais uma avaliação nestas mesmas fatias para comparar se as técnicas detectavam mais lesões com ou sem filtro (Tabela 6). Para tal, realizou-se a segmentação por contornos ativos diretamente na imagem original sem realizar nenhum tipo de processamento.

Tabela 6 - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste sem aplicação de filtros e sem alargamento de contraste.

Teste sem alargamento de contraste e sem filtros				
Fatia	Nº de pixels brancos		Área de lesões detectada (mm ²)	
	MATLAB ACM	ORACM	MATLAB ACM	ORACM
Exame 9a_siemens_modiCASGMBH_2mm				
00064	254	259	116.00	122.85
00127	467	495	213.27	226.06
00191	975	1040	445.26	474.95
Exame 10a_siemens_modiCASGMBH_2mm				
00068	14196	126	1001.30	88.8725
00199	789	862	556.51	608.00
Exame 11a_siemens_modiCASGMBH_2mm				
00071	7777	17	7416.70	16.21

Fonte: autoria própria.

Comparando as Tabela 6 e Tabela 4, é possível observar que, sem os filtros, os dois métodos de contorno ativo conseguiram detectar mais lesões. Assim, para os testes dos três exames completos, realizou-se testes com e sem alargamento de contraste, porém, sem a aplicação de filtros.

5.3 Bloco de Testes 02: Testes Exame Completo

O Apêndice deste trabalho reúne todos os resultados das áreas detectadas pelos dois métodos de contorno ativo para todas as fatias dos três exames completos. Nesta seção, serão tratados alguns dos resultados que se julgou mais interessante de se discutir. Dessa forma, as Tabela 7 e Tabela 8 reúnem as áreas de lesões detectadas das fatias que serão analisadas.

A área detectada pelas duas técnicas foi similar na maioria das fatias testadas, contudo, houve fatias que apresentaram erros de detecção. Nas Tabelas 7 e Tabela 8, tem-se um exemplo de cada caso.

Os destaques em vermelho referem-se a erros na detecção de lesões quando a técnica detecta o contorno externo dos pulmões ao invés de detectar as lesões, gerando uma área maior e errônea. Já os destaques em azul referem-se a erros gerados pela extração dos pulmões em que partes que compreendem os pulmões foram eliminadas.

5.3.1 Teste exame completo com alargamento de contraste

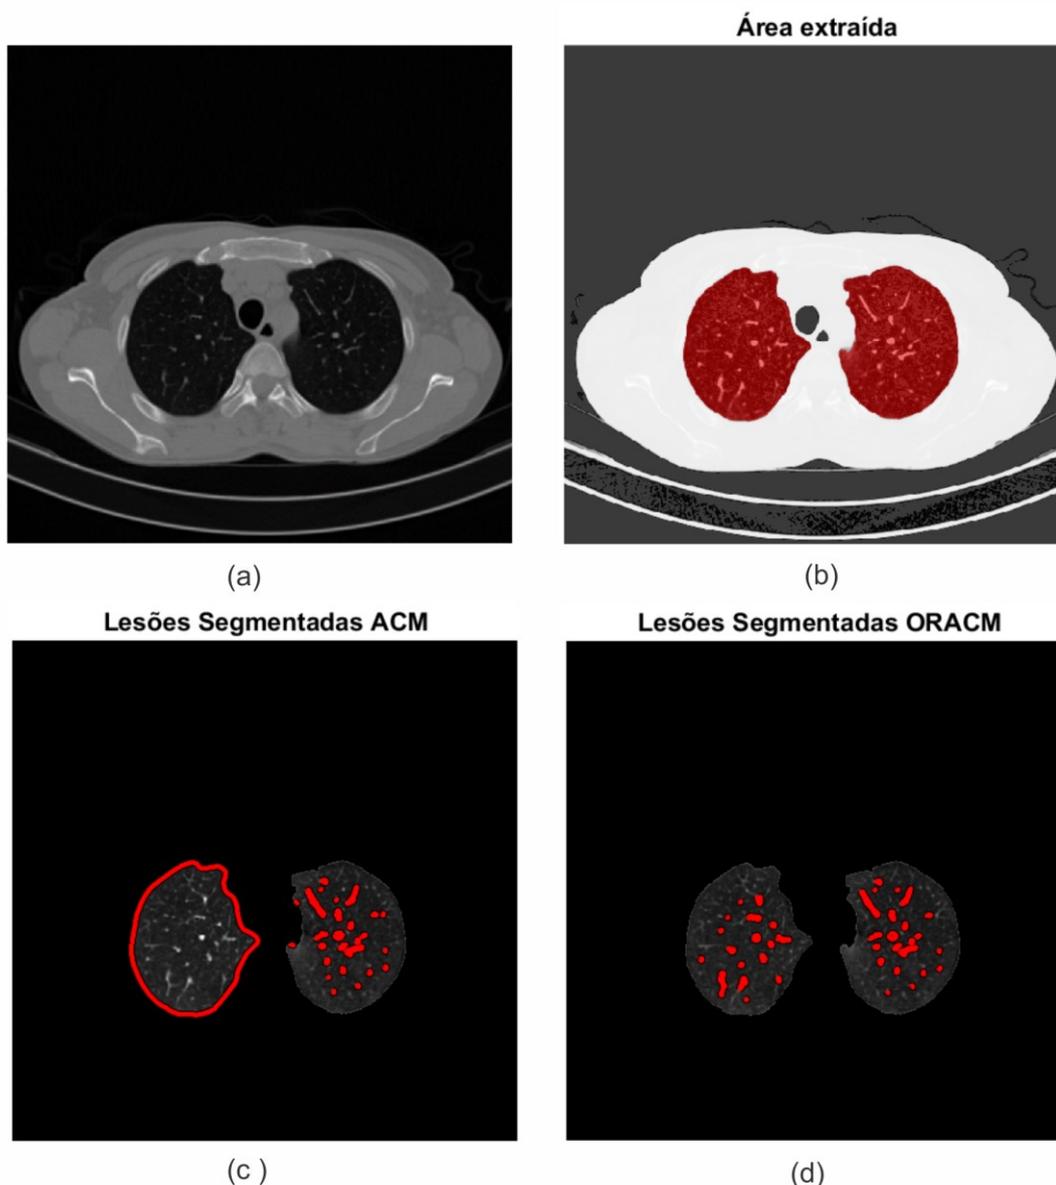
Tabela 7 - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM de algumas fatias do teste do exame completo sem aplicação de filtros e com alargamento de contraste.

Teste exame completo com alargamento de contraste e sem filtros				
Fatia	Nº de pixels brancos		Área de lesões detectada (mm ²)	
	MATLAB ACM	ORACM	MATLAB ACM	ORACM
Exame 9a_siemens_modiCASGMBH_2mm				
00060	2198	773	1003.78	353.01
00143	1756	1830	801.93	835.72
00205	2871	3249	1311.13	1483.75
00206	1237	1487	564.91	679.08
Exame 10a_siemens_modiCASGMBH_2mm				
00153	4131	1064	2913.75	750.48
00193	2818	2917	1987.64	2057.47
00231	1712	266	1207.54	187.62
Exame 11a_siemens_modiCASGMBH_2mm				
00098	3931	725	3748.89	691.41
00151	6735	1127	6423	1074.79
00227	3238	2879	3088	2745.63
00230	12168	12226	11604.31	11659.62

Fonte: autoria própria.

Começando a análise pela Tabela 7, na fatia 00060 do exame 9a_siemens_modiCASGMBH_2mm, a técnica MATLAB ACM detectou o contorno externo do pulmão esquerdo, não detectando as lesões desta região, assim, a área contabilizada como a área de lesões é maior e errônea (Figura 32 - c). Nesta mesma fatia, a técnica ORACM conseguiu identificar lesões, conforme mostrado na Figura 32 - d.

Figura 32 - Teste exame completo com alargamento de contraste sem filtros para a fatia 00060 do exame 9a_siemens_modiCASGMBH_2mm. (a) Imagem original; (b) Imagem com alargamento de contraste com área dos pulmões que foi extraída destacada em vermelho; (c) Detecção realizada pelo método MATLAB ACM destacada em vermelho; (d) Detecção realizada pelo método ORACM destacada em vermelho.

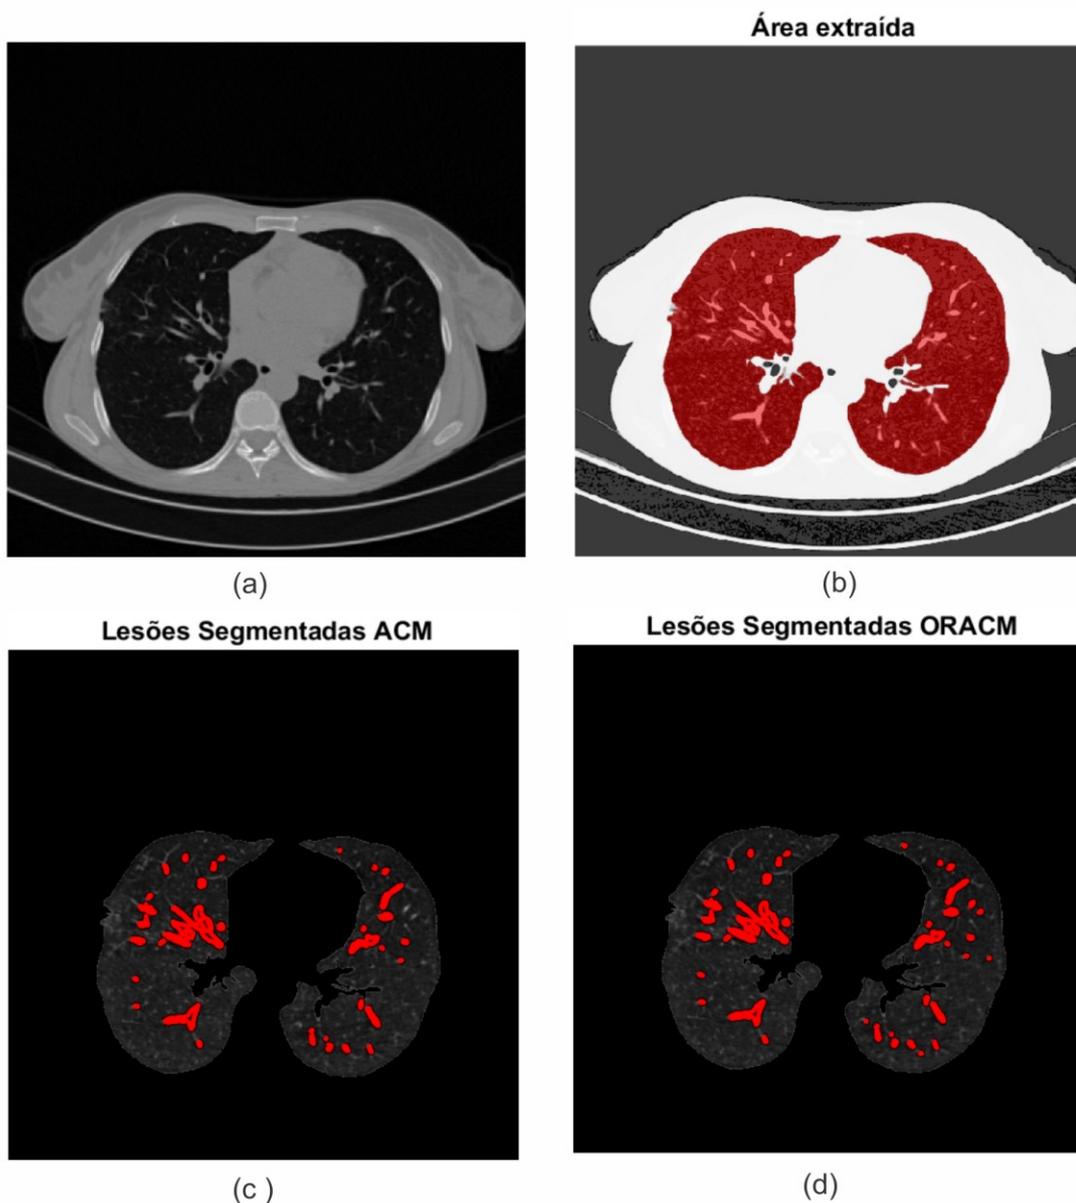


Fonte: autoria própria.

Ainda, ORACM conseguiu detectar mais de lesões do que a MATLAB ACM conforme observado pelas diferenças entre as áreas calculadas. Estas diferenças foram maiores do que no teste com o alargamento de contraste.

Na fatia 00143 do exame 9a_siemens_modiCASGMBH_2mm, as duas técnicas conseguiram detectar boa parte das lesões e a extração dos pulmões foi bem-sucedida (Figura 33). Na análise quantitativa (Tabela 7), é possível observar que a técnica ORACM conseguiu detectar uma área de lesões maior.

Figura 33 - Teste exame completo com alargamento de contraste sem filtros para a fatia 00143 do exame 9a_siemens_modiCASGMBH_2mm. (a) Imagem original; (b) Imagem com alargamento de contraste com área dos pulmões que foi extraída destacada em vermelho; (c) Detecção realizada pelo método MATLAB ACM destacada em vermelho; (d) Detecção realizada pelo método ORACM destacada em vermelho.

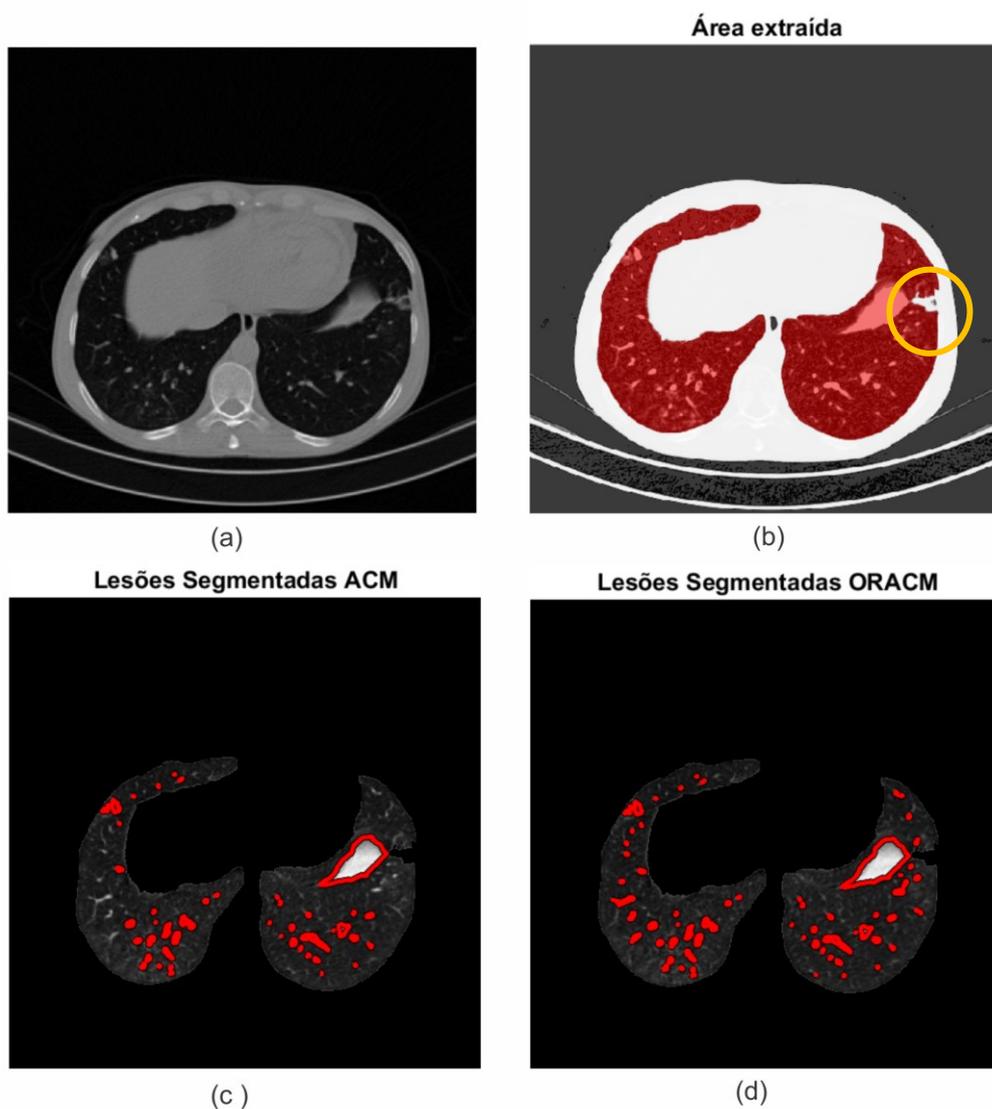


Fonte: autoria própria.

Nas fatias 00205 e 00206 do exame 9a_siemens_modiCASGMBH_2mm, observa-se, respectivamente, uma pequena lesão e uma grande porção que não foram consideradas como parte do pulmão direito (Figura 34 e Figura 35). Entretanto, os dois métodos conseguiram identificar lesões na área que foi efetivamente extraída e, novamente, a área contabilizada pelo ORACM foi um pouco maior. Além disso, na fatia 00206, é possível observar que, devido à falha de extração da área pulmonar,

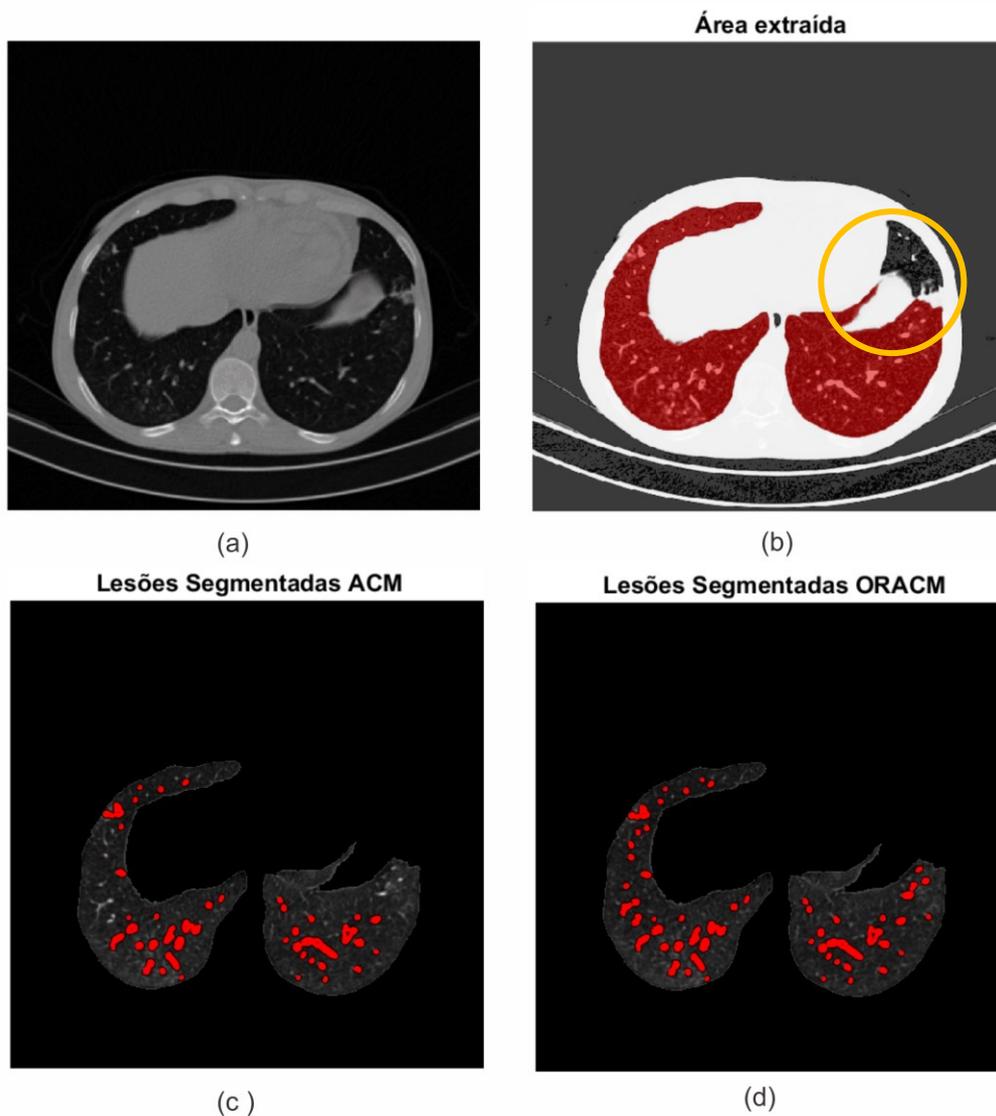
uma importante lesão foi eliminada, gerando uma área errônea e, na fatia 00205, foi eliminado um pedaço do pulmão (indicações em amarelo):

Figura 34 - Teste exame completo com alargamento de contraste sem filtros para a fatia 00205 do exame 9a_siemens_modiCASGMBH_2mm. (a) Imagem original; (b) Imagem com alargamento de contraste com área dos pulmões que foi extraída destacada em vermelho; (c) Detecção realizada pelo método MATLAB ACM destacada em vermelho; (d) Detecção realizada pelo método ORACM destacada em vermelho.



Fonte: autoria própria.

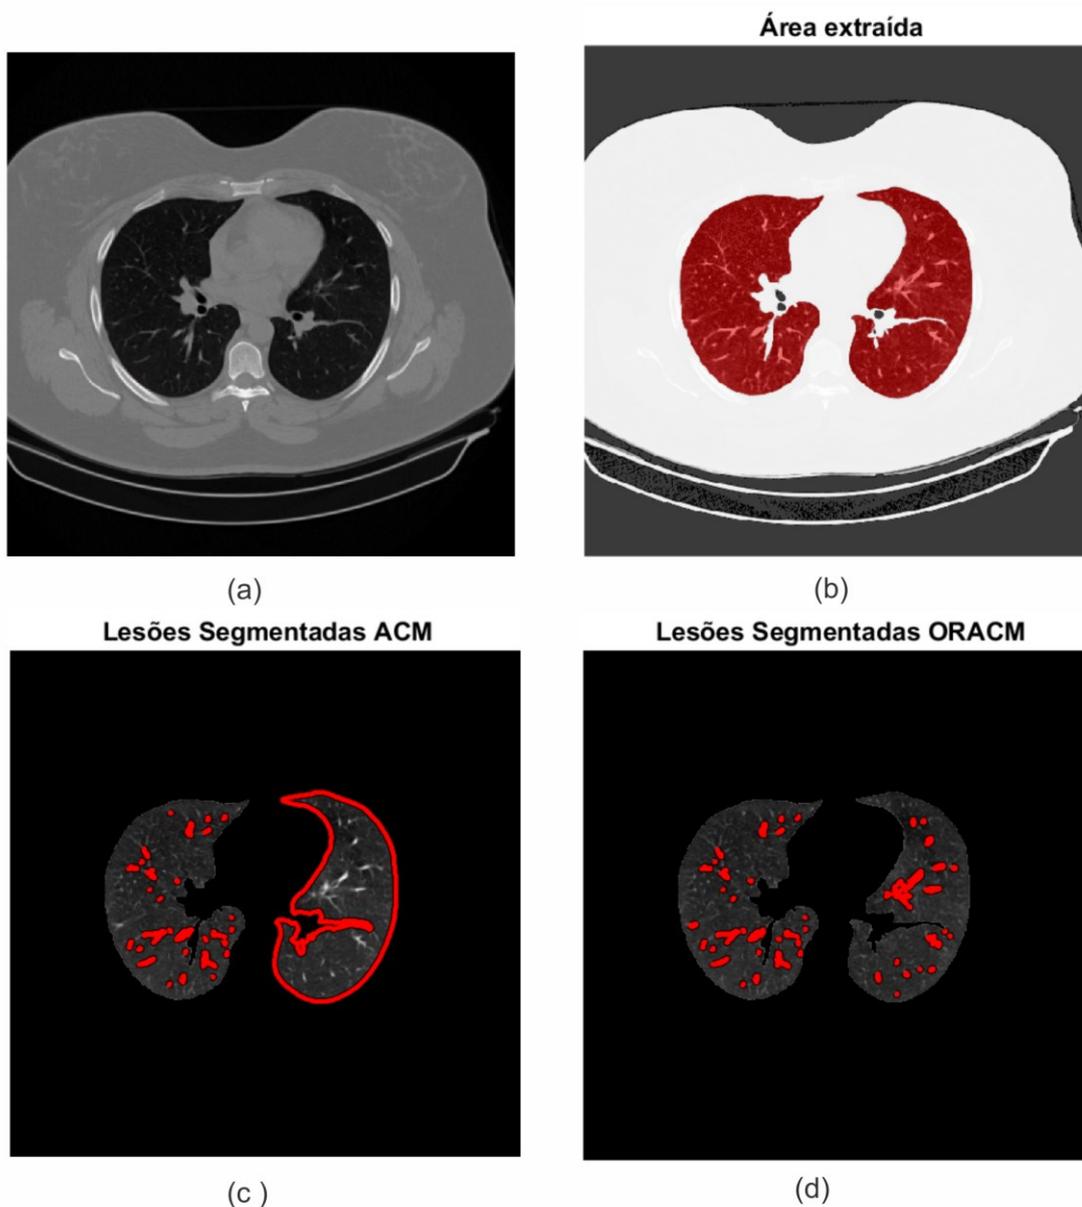
Figura 35 – Teste exame completo com alargamento de contraste sem filtros para a fatia 00206 do exame 9a_siemens_modiCASGMBH_2mm. (a) Imagem original; (b) Imagem com alargamento de contraste com área dos pulmões que foi extraída destacada em vermelho; (c) Detecção realizada pelo método MATLAB ACM destacada em vermelho; (d) Detecção realizada pelo método ORACM destacada em vermelho.



Fonte: autoria própria.

Analisando o segundo exame, na fatia 00153, a técnica MATLAB ACM detectou o contorno externo do pulmão direito, não detectando as lesões desta região, assim, a área contabilizada como a área de lesões é maior e errônea (Figura 36 - c). Nesta mesma fatia, a técnica ORACM conseguiu identificar lesões, conforme mostrado na Figura 36 - d.

Figura 36 - Teste exame completo com alargamento de contraste sem filtros para a fatia 00153 do exame 10a_siemens_modiCASGMBH_2mm. (a) Imagem original; (b) Imagem com alargamento de contraste com área dos pulmões que foi extraída destacada em vermelho; (c) Detecção realizada pelo método MATLAB ACM destacada em vermelho; (d) Detecção realizada pelo método ORACM destacada em vermelho.



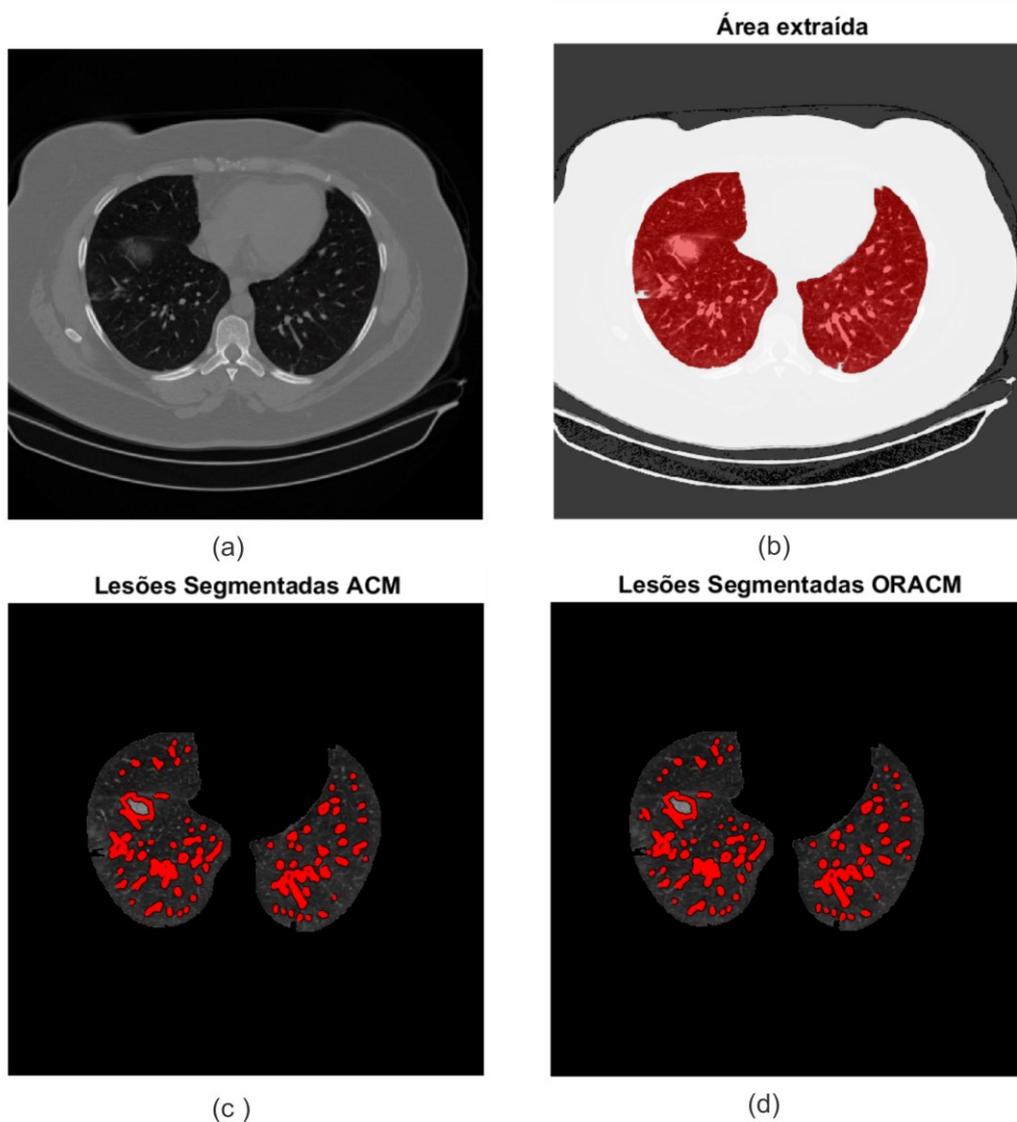
Fonte: autoria própria.

Na fatia 00193 do exame 10a_siemens_modiCASGMBH_2mm, tem-se um exemplo de uma ótima segmentação dos pulmões e das lesões. As duas técnicas conseguiram detectar boa parte das lesões e a extração dos pulmões foi bem-sucedida (Figura 37). Na análise quantitativa (Tabela 7), também se observa que a técnica ORACM conseguiu detectar uma área de lesões maior.

Na fatia 00231, a técnica MATLAB ACM detectou o contorno externo do pulmão esquerdo, não detectando as lesões desta região (Figura 38 - c). Nesta mesma fatia,

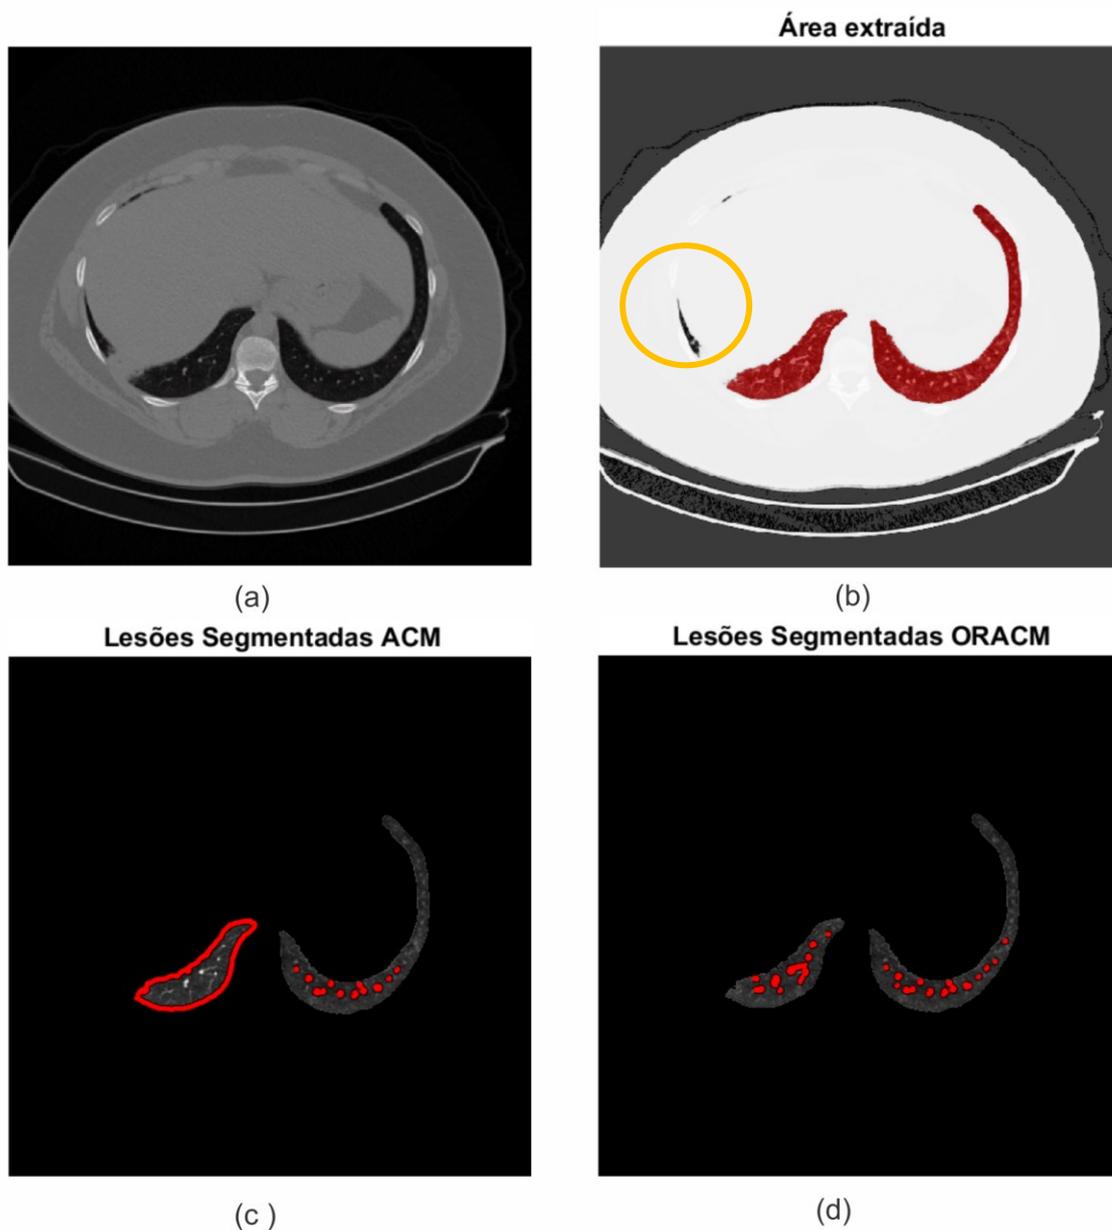
a técnica ORACM conseguiu identificar lesões, conforme mostrado na Figura 38 – d. Porém, observa-se que uma pequena porção do pulmão esquerdo não foi considerada devido à junção entre uma lesão pulmonar e os outros tecidos presentes na imagem.

Figura 37 - Teste exame completo com alargamento de contraste sem filtros para a fatia 00193 do exame 10a_siemens_modiCASGMBH_2mm. (a) Imagem original; (b) Imagem com alargamento de contraste com área dos pulmões que foi extraída destacada em vermelho; (c) Detecção realizada pelo método MATLAB ACM destacada em vermelho; (d) Detecção realizada pelo método ORACM destacada em vermelho.



Fonte: autoria própria.

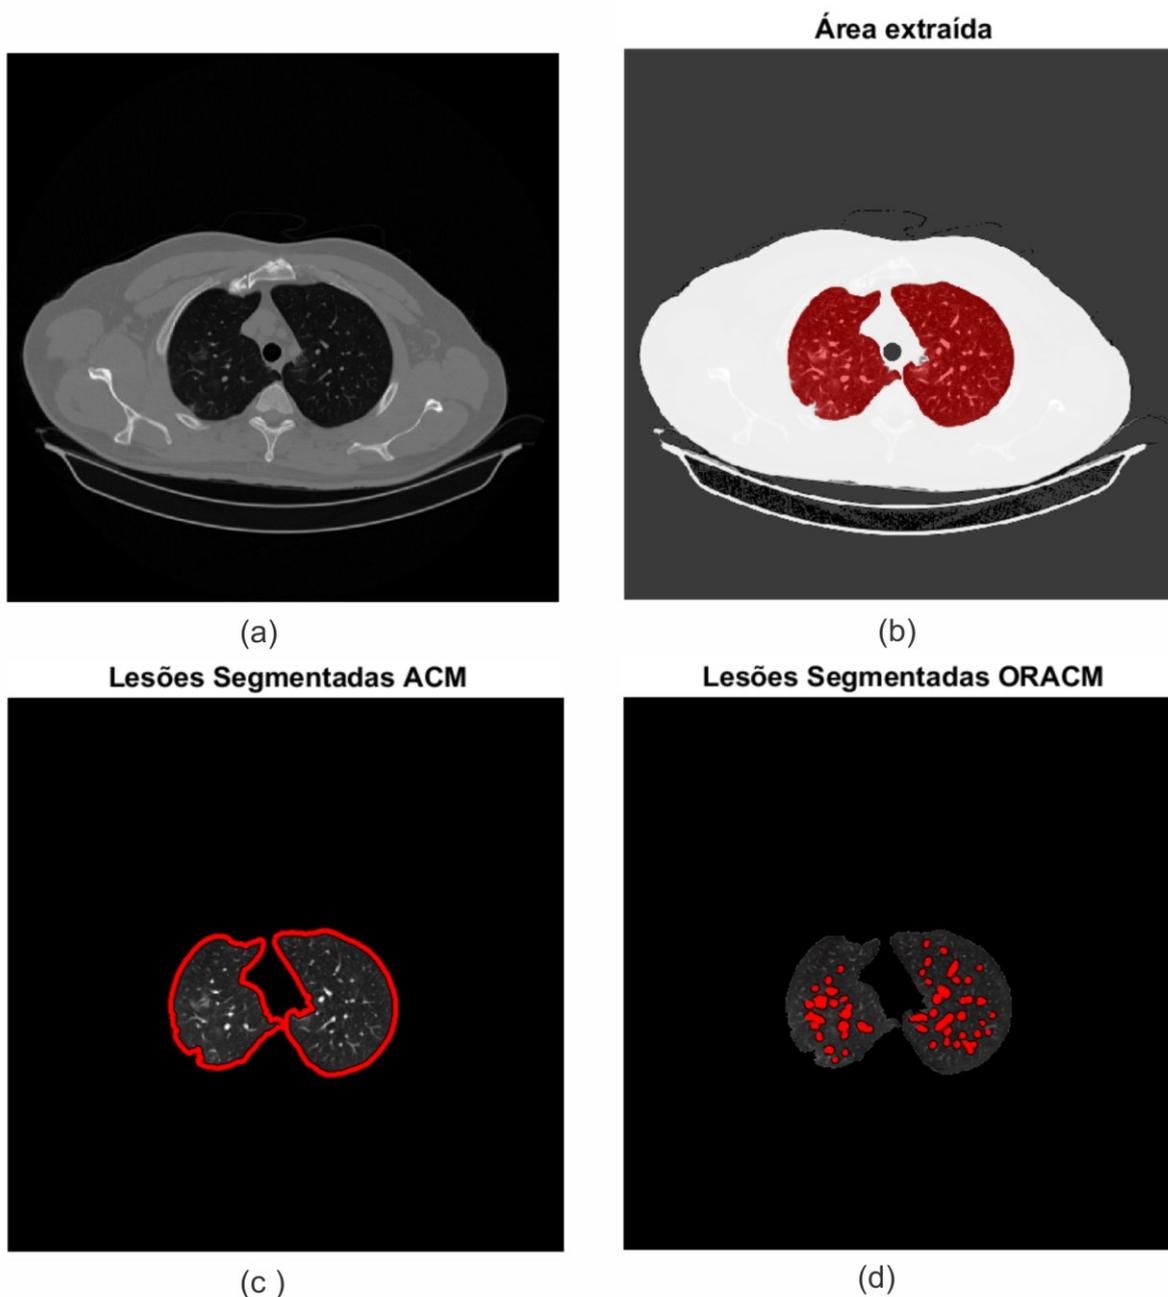
Figura 38 - Teste exame completo com alargamento de contraste sem filtros para a fatia 00231 do exame 10a_siemens_modiCASGMBH_2mm. (a) Imagem original; (b) Imagem com alargamento de contraste com área dos pulmões que foi extraída destacada em vermelho; (c) Detecção realizada pelo método MATLAB ACM destacada em vermelho; (d) Detecção realizada pelo método ORACM destacada em vermelho.



Fonte: autoria própria.

Na fatia 00098 do último exame, a técnica MATLAB ACM detectou o contorno externo dos pulmões e não detectou as lesões, assim, a área contabilizada como a área de lesões é maior e errônea (Figura 39 - c). Nesta mesma fatia, a técnica ORACM conseguiu identificar lesões, conforme mostrado na Figura 39 - d.

Figura 39 - Teste exame completo com alargamento de contraste sem filtros para a fatia 00098 do exame 11a_siemens_modiCASGMBH_2mm. (a) Imagem original; (b) Imagem com alargamento de contraste com área dos pulmões que foi extraída destacada em vermelho; (c) Detecção realizada pelo método MATLAB ACM destacada em vermelho; (d) Detecção realizada pelo método ORACM destacada em vermelho.



Fonte: autoria própria.

O mesmo ocorreu na fatia 00151 deste exame (Figura 40), contudo, também ocorreu um erro na extração dos pulmões em que foram eliminadas as porções referentes a uma lesão do pulmão esquerdo e a um pedaço significativo do pulmão direito. Dessa forma, apesar do ORACM ter detectado as lesões da área que foi extraída, a área de lesões contabilizada não condiz com a realidade.

Com relação à fatia 00227, observa-se que um tumor de tamanho significativo foi eliminado durante o processamento da máscara de segmentação dos pulmões (Figura 41). Ainda, pequenas lesões próximas à borda dos pulmões não foram consideradas. Entretanto, os dois métodos conseguiram identificar lesões na área que foi efetivamente extraída e, novamente, a área contabilizada pelo ORACM foi maior.

Figura 40 - Teste exame completo com alargamento de contraste sem filtros para a fatia 00151 do exame 11a_siemens_modiCASGMBH_2mm. (a) Imagem original; (b) Imagem com alargamento de contraste com área dos pulmões que foi extraída destacada em vermelho; (c) Detecção realizada pelo método MATLAB ACM destacada em vermelho; (d) Detecção realizada pelo método ORACM destacada em vermelho.

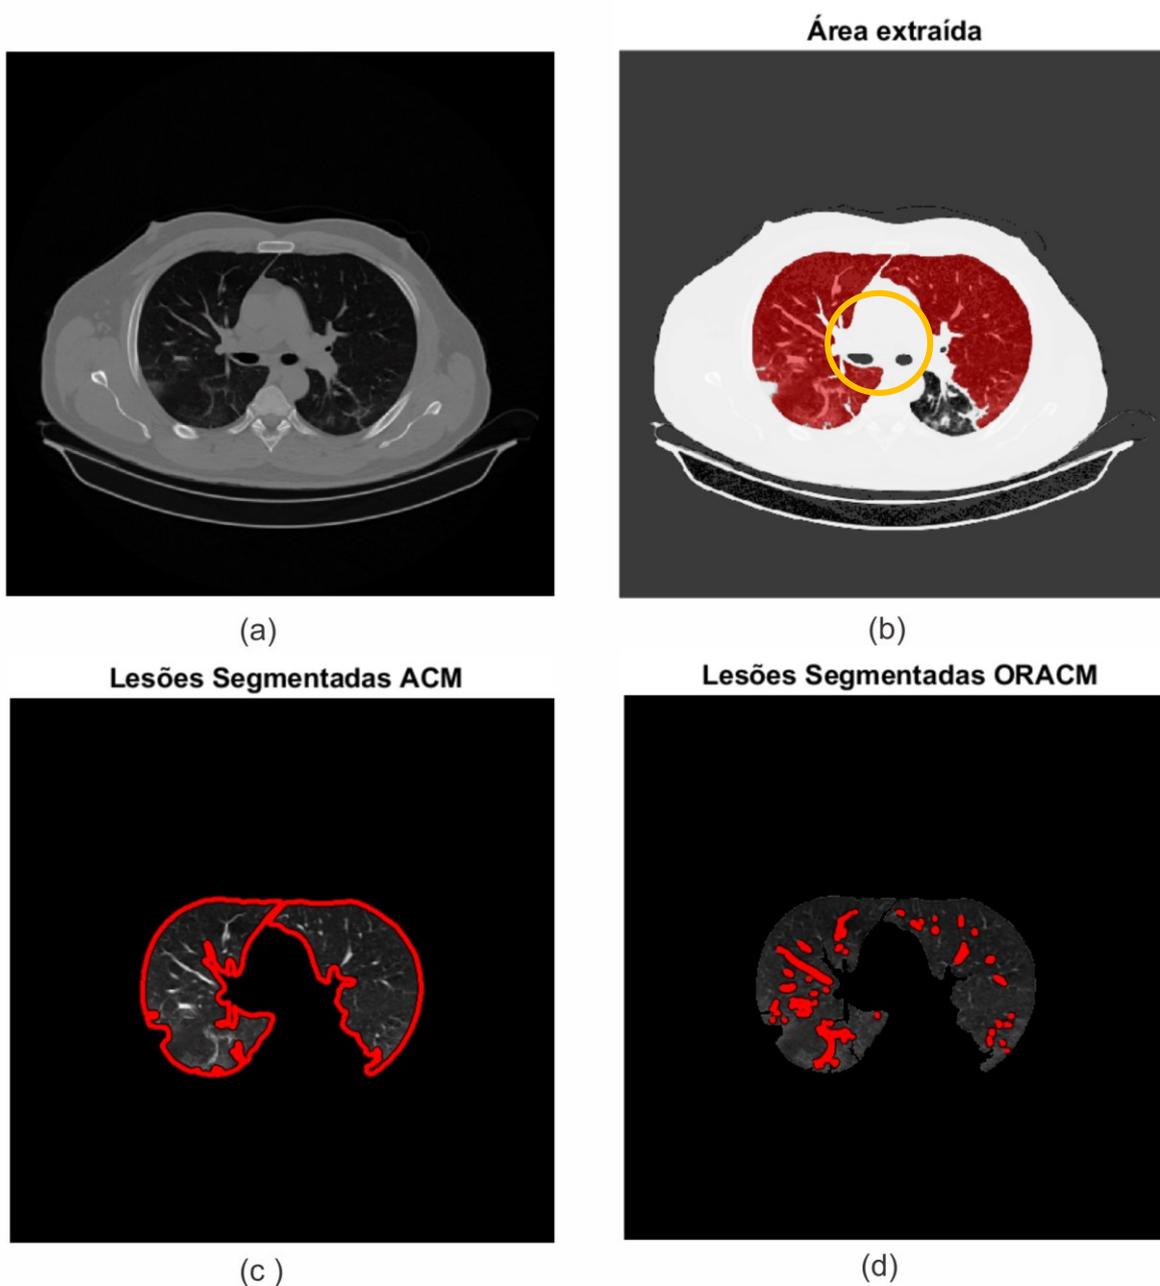
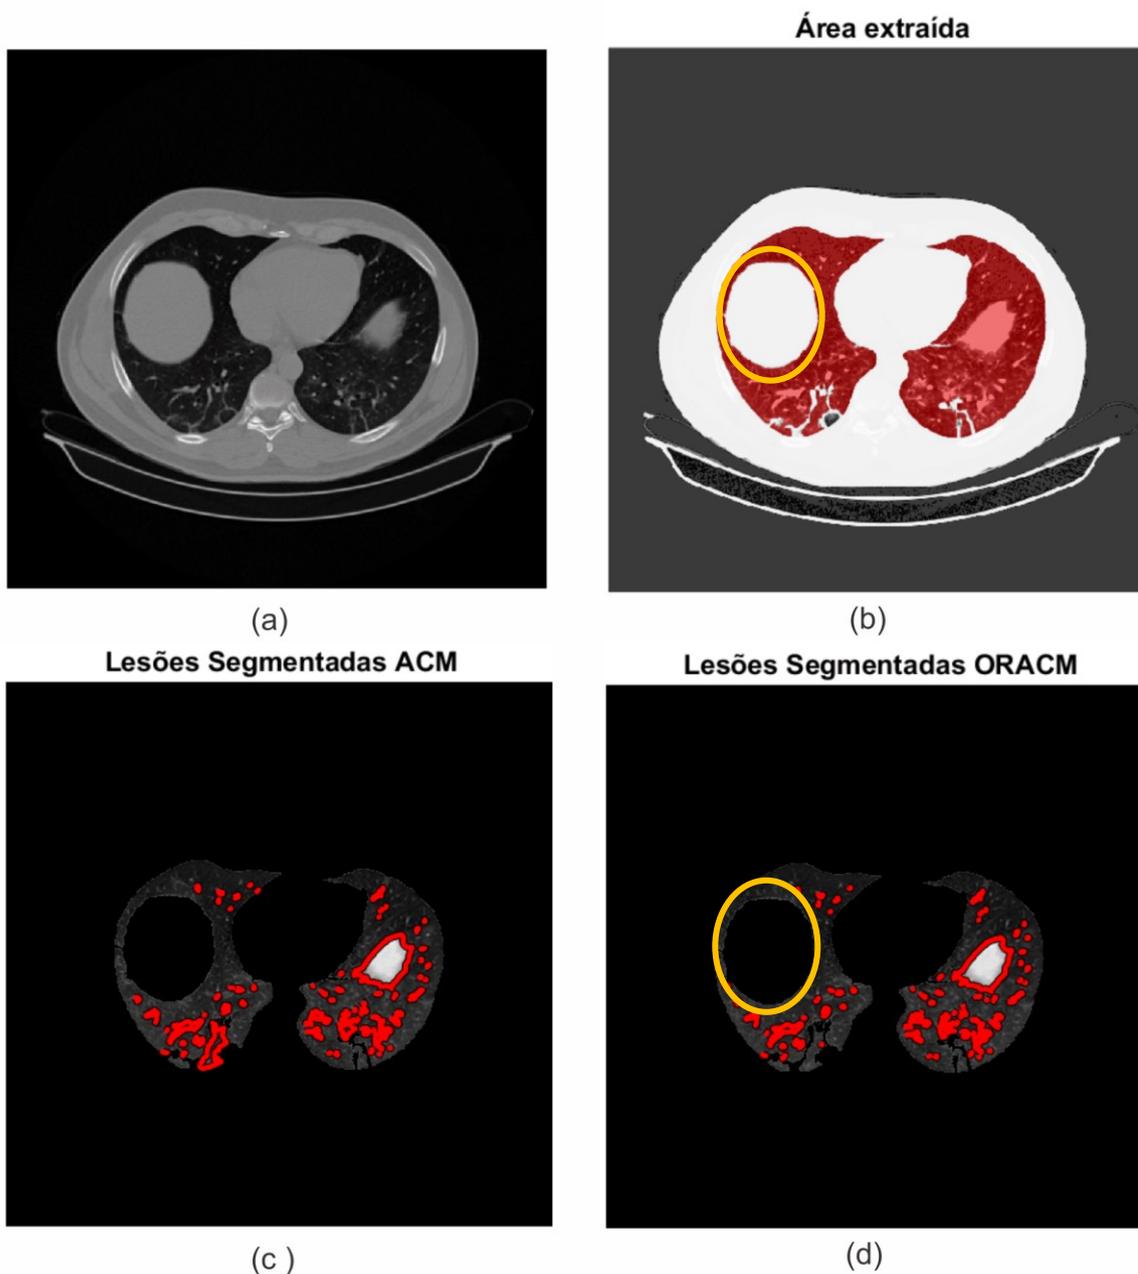


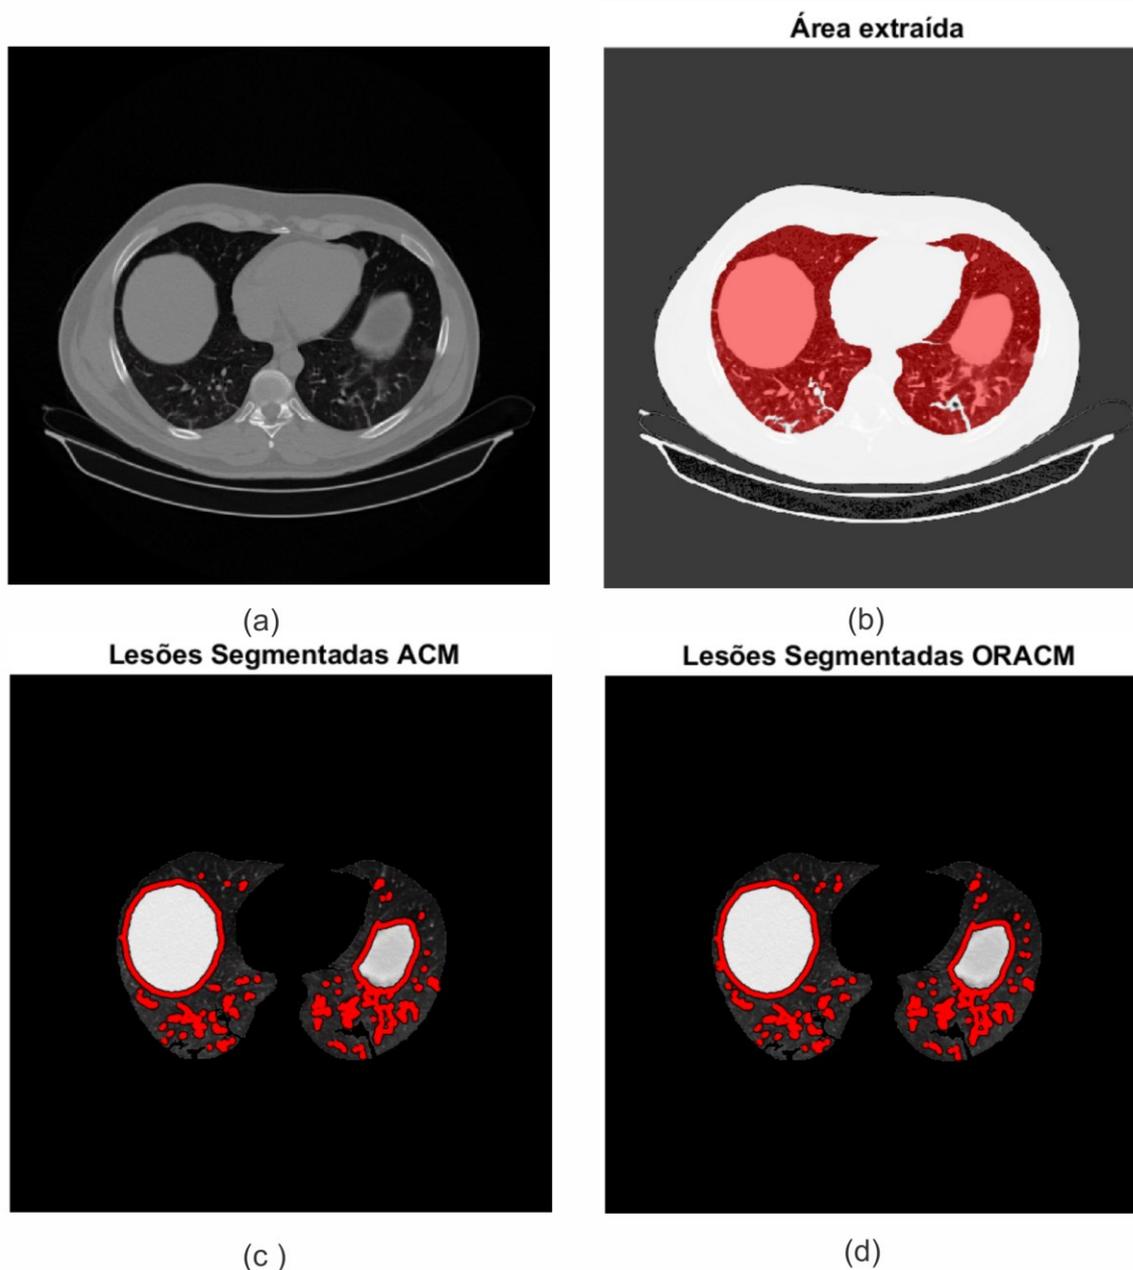
Figura 41 - Teste exame completo com alargamento de contraste sem filtros para a fatia 00227 do exame 11a_siemens_modiCASGMBH_2mm. (a) Imagem original; (b) Imagem com alargamento de contraste com área dos pulmões que foi extraída destacada em vermelho; (c) Detecção realizada pelo método MATLAB ACM destacada em vermelho; (d) Detecção realizada pelo método ORACM destacada em vermelho.



Fonte: autoria própria.

Já na fatia 00230, os dois tumores foram considerados e identificados pelas duas técnicas, tendo-se um exemplo de uma ótima segmentação dos pulmões e das lesões (Figura 42). Na análise quantitativa (Tabela 7), também se observa que a técnica ORACM conseguiu detectar uma área de lesões maior.

Figura 42 - Teste exame completo com alargamento de contraste sem filtros para a fatia 00230 do exame 11a_siemens_modiCASGMBH_2mm. (a) Imagem original; (b) Imagem com alargamento de contraste com área dos pulmões que foi extraída destacada em vermelho; (c) Detecção realizada pelo método MATLAB ACM destacada em vermelho; (d) Detecção realizada pelo método ORACM destacada em vermelho.



Fonte: autoria própria.

5.3.2 Teste exame completo sem alargamento de contraste

Analisando os resultados sem alargamento de contraste para essas mesmas fatias (Tabela 8), da mesma forma que no teste anterior, na fatia 00060 do exame 9a_siemens_modiCASGMBH_2mm, a técnica MATLAB ACM detectou o contorno

externo do pulmão esquerdo, não detectando as lesões desta região, contabilizando uma área errônea. Já o ORACM conseguiu identificar lesões.

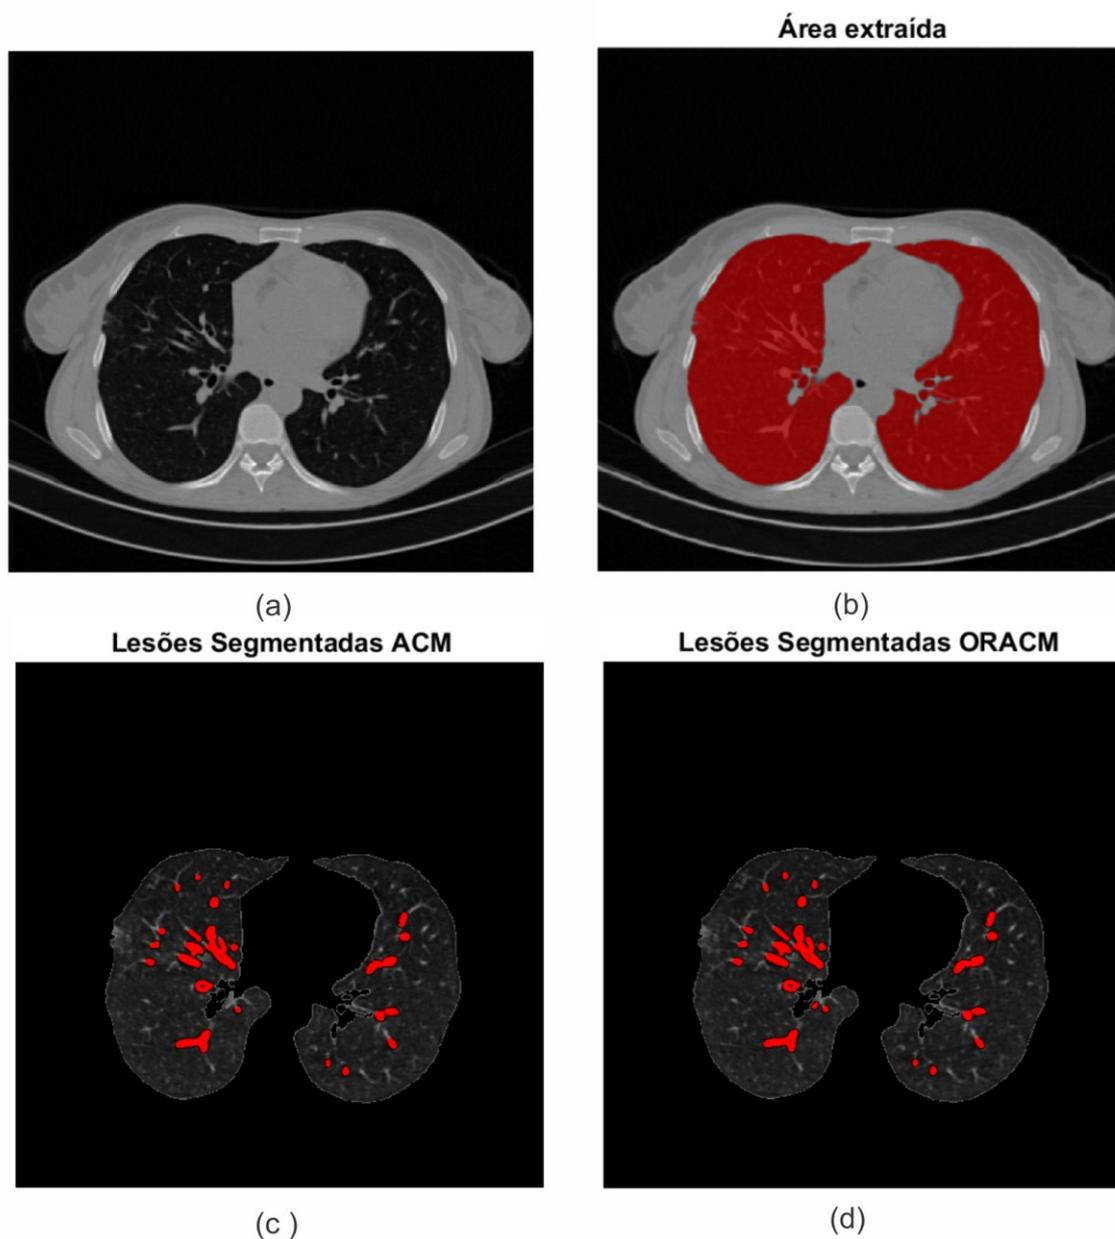
Para a fatia 00143, a extração dos pulmões foi bem-sucedida e as duas técnicas conseguiram detectar parte das lesões, porém é possível observar que muitas lesões não foram detectadas (Figura 43).

Tabela 8 - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM de algumas fatias do teste do exame completo sem aplicação de filtros e sem alargamento de contraste.

Teste exame completo sem alargamento de contraste e sem filtros				
Fatia	Nº de pixels brancos		Área de lesões detectada (mm ²)	
	MATLAB ACM	ORACM	MATLAB ACM	ORACM
Exame 9a_siemens_modiCASGMBH_2mm				
00060	14523	244	6632.37	111.43
00143	977	1012	446.18	462.16
00205	1877	2017	857.19	921.12
00206	2534	2660	1157.23	1214.77
Exame 10a_siemens_modiCASGMBH_2mm				
00153	16969	557	11968.87	392.87
00193	1344	1444	947.97	1018.51
00231	86	99	60.66	69.83
Exame 11a_siemens_modiCASGMBH_2mm				
00098	19576	279	18669.13	266.08
00151	28445	523	27127.27	498.77
00227	8692	8686	8289.34	8283.62
00230	11024	11017	10513.31	10506.63

Fonte: autoria própria.

Figura 43 - Teste exame completo sem alargamento de contraste e sem filtros para a fatia 00143 do exame 9a_siemens_modiCASGMBH_2mm. (a) Imagem original; (b) Imagem original com área dos pulmões que foi extraída destacada em vermelho; (c) Detecção realizada pelo método MATLAB ACM destacada em vermelho; (d) Detecção realizada pelo método ORACM destacada em vermelho.

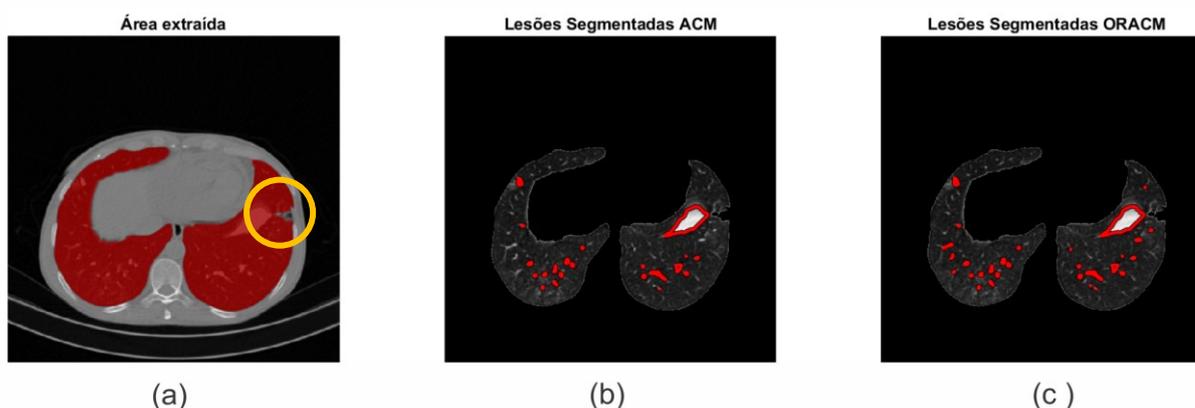


Fonte: autoria própria.

Nas fatias 00205 e 00206 do exame 9a_siemens_modiCASGMBH_2mm, observa-se que uma pequena lesão não foi considerada como parte do pulmão direito em ambas imagens (Figura 44 e Figura 45). Entretanto, os dois métodos conseguiram identificar lesões na área que foi efetivamente extraída e, novamente, a área contabilizada pelo ORACM foi maior. Além disso, é importante ressaltar que a extração dos pulmões foi melhor no teste sem a realização do alargamento de

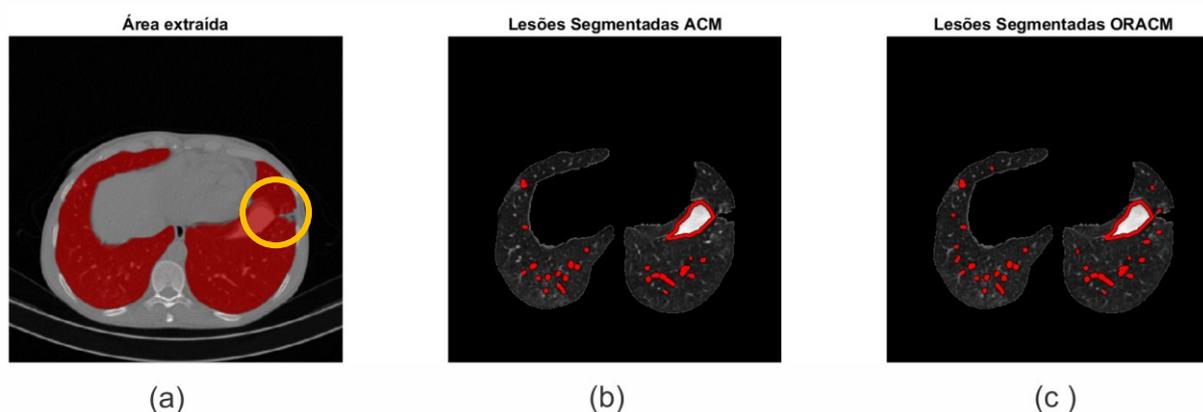
contraste para a fatia 00206, pois não ocorreu a falha de extração de uma porção significativa do pulmão como ocorreu no teste anterior mostrado na Figura 35.

Figura 44 – Teste exame completo sem alargamento de contraste e sem filtros para a fatia 00205 do exame 9a_siemens_modiCASGMBH_2mm. (a) Imagem original com área dos pulmões que foi extraída destacada em vermelho; (b) Detecção realizada pelo método MATLAB ACM destacada em vermelho; (c) Detecção realizada pelo método ORACM destacada em vermelho



Fonte: autoria própria.

Figura 45 - Teste exame completo sem alargamento de contraste e sem filtros para a fatia 00206 do exame 9a_siemens_modiCASGMBH_2mm. (a) Imagem original com área dos pulmões que foi extraída destacada em vermelho; (b) Detecção realizada pelo método MATLAB ACM destacada em vermelho; (c) Detecção realizada pelo método ORACM destacada em vermelho



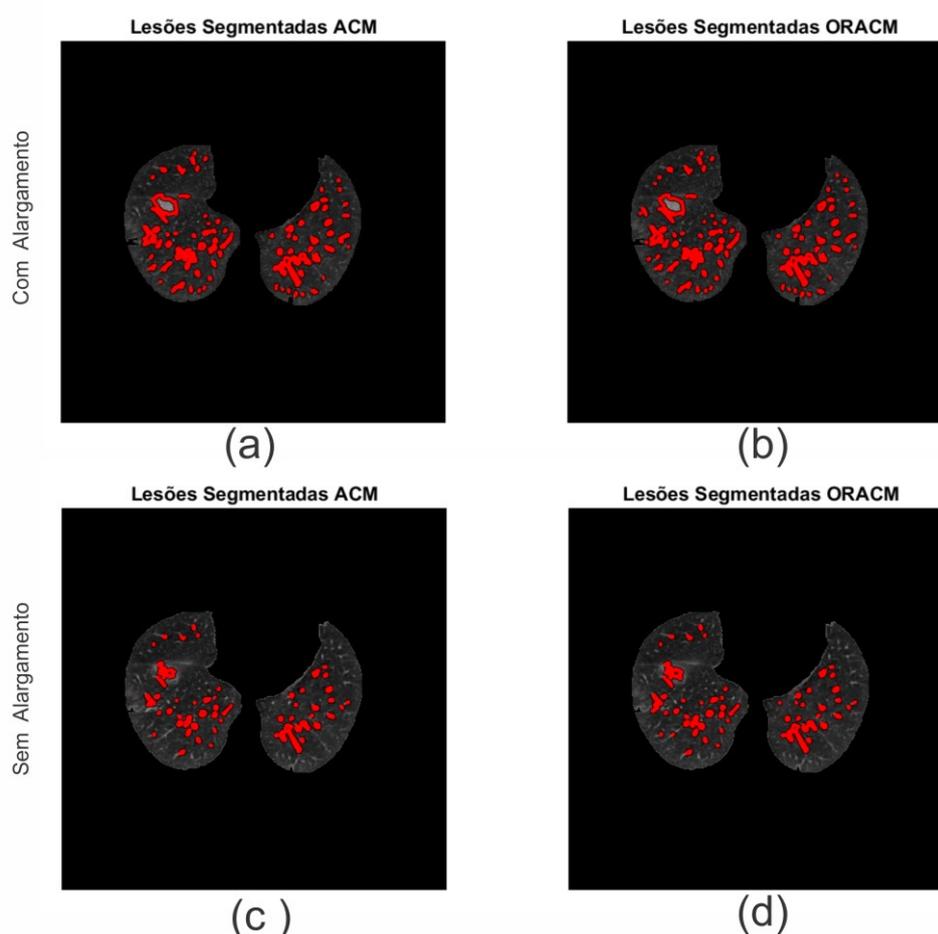
Fonte: autoria própria.

Analisando o segundo exame, assim como no teste anterior, para a fatia 00153, a técnica MATLAB ACM detectou o contorno externo do pulmão direito, sem detectar as lesões desta região. Já o ORACM conseguiu identificar lesões. Conforme a Tabela 8, a área identificada pelo ORACM foi maior com a aplicação do alargamento de contraste.

Para a fatia 00193 do exame 10a_siemens_modiCASGMBH_2mm, a extração dos pulmões foi bem-sucedida e as duas técnicas conseguiram detectar boa parte das

lesões (Figura 46 – c, d). Porém, ao comparar as os resultados com e sem alargamento de contraste (Figura 46), é possível observar que o formato das lesões foi melhor delineado pelos contornos ativos com o alargamento de contraste. Na análise quantitativa (Tabela 7 e 8), também se observa que a técnica ORACM conseguiu detectar uma área de lesões um pouco maior e que mais lesões foram identificadas com a aplicação do alargamento de contraste.

Figura 46 – Comparação dos resultados com e sem alargamento de contraste para a fatia 00193 do exame 10a_siemens_modiCASGMBH_2mm. (a) Detecção realizada pelo método MATLAB ACM destacada em vermelho, com alargamento de contraste; (b) Detecção realizada pelo método ORACM destacada em vermelho com alargamento de contraste; (c) Detecção realizada pelo método MATLAB ACM destacada em vermelho, sem alargamento de contraste; (d) Detecção realizada pelo método ORACM destacada em vermelho, sem alargamento de contraste.

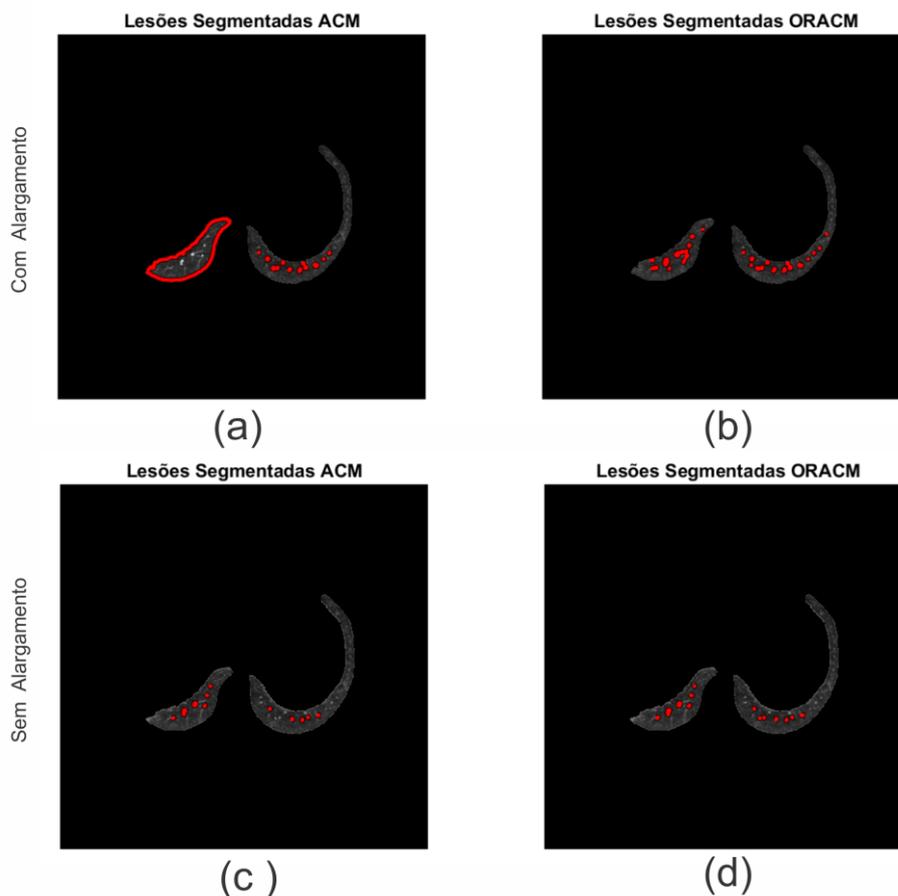


Fonte: autoria própria.

Na fatia 00231, observa-se que uma pequena porção do pulmão esquerdo não foi considerada devido à junção entre uma lesão pulmonar e os outros tecidos presentes na imagem (Figura 47). Entretanto, as duas técnicas conseguiram detectar lesões, diferentemente do ocorrido no teste anterior. Com o alargamento de contraste,

o MATLAB ACM detectou o contorno externo do pulmão esquerdo, o que não ocorreu sem essa operação (Figura 47).

Figura 47 - Comparação dos resultados com e sem alargamento de contraste para a fatia 00231 do exame 10a_siemens_modiCASGMBH_2mm. (a) Detecção realizada pelo método MATLAB ACM destacada em vermelho, com alargamento de contraste; (b) Detecção realizada pelo método ORACM destacada em vermelho com alargamento de contraste; (c) Detecção realizada pelo método MATLAB ACM destacada em vermelho, sem alargamento de contraste; (d) Detecção realizada pelo método ORACM destacada em vermelho, sem alargamento de contraste.



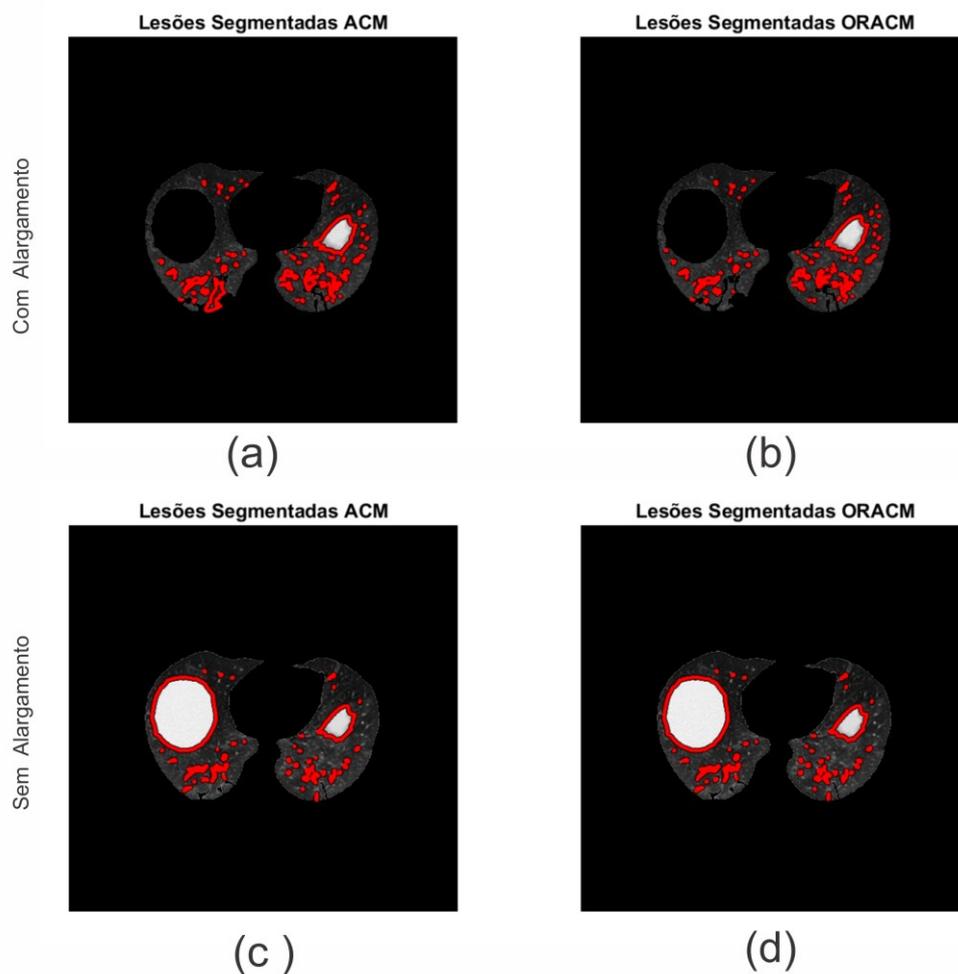
Fonte: autoria própria.

Assim como no teste anterior, o MATLAB ACM detectou o contorno externo dos pulmões e não detectou as lesões na fatia 00098 do último exame. Já o ORACM conseguiu identificar lesões. O mesmo ocorreu na fatia 00151 deste exame, contudo, o erro de extração dos pulmões que ocorreu no teste com alargamento de contraste (Figura 40) não ocorreu. Ainda, a quantidade de lesões identificadas pelo ORACM foi bem menor do que no teste anterior.

Com relação à fatia 00227, observa-se que o tumor de tamanho significativo, que havia sido eliminado no teste com alargamento de contraste, foi identificado neste

caso (Figura 48). Assim, os dois métodos conseguiram identificar lesões e, novamente, a área contabilizada pelo ORACM foi maior.

Figura 48 - Comparação dos resultados com e sem alargamento de contraste para a fatia 00231 do exame 10a_siemens_modiCASGMBH_2mm. (a) Detecção realizada pelo método MATLAB ACM destacada em vermelho, com alargamento de contraste; (b) Detecção realizada pelo método ORACM destacada em vermelho com alargamento de contraste; (c) Detecção realizada pelo método MATLAB ACM destacada em vermelho, sem alargamento de contraste; (d) Detecção realizada pelo método ORACM destacada em vermelho, sem alargamento de contraste.



Fonte: autoria própria.

Similarmente, na fatia 00230, os dois tumores foram considerados e identificados pelas duas técnicas, tendo-se um exemplo de uma boa segmentação dos pulmões e das lesões. Porém, pela análise quantitativa é possível verificar que se detectou mais lesões com a aplicação do alargamento de contraste. Também se observa que a técnica ORACM conseguiu detectar uma área de lesões maior.

5.4 Média e desvio padrão

Reunindo os resultados de todos os testes, a fim de comparar todos os resultados qualitativos, foram realizados os cálculos da média e do desvio padrão totais para cada um dos testes e métodos (Tabela 9).

Tabela 9 – Média e desvio padrão de todas as fatias dos três exames para cada teste.

Média e desvio padrão de todos os resultados						
		Nº de pixels brancos		Área de lesões detectada (mm ²)		
		MATLAB ACM	ORACM	MATLAB ACM	ORACM	
Considerando todas as fatias dos três exames						
Bloco de Testes 01: Testes Preliminares						
Teste 1 - Teste com alargamento de contraste e filtro de média 3x3	Média total	1723.83	1003.17	1091.93	544.65	
	Desvio padrão	1298.04	836.82	944.11	462.89	
Teste 2 - Teste com alargamento de contraste e filtro de mediana 3x3	Média total	1693.67	947.67	1102.73	510.61	
	Desvio padrão	1033.29	796.46	800.26	430.19	
Teste 3 - Teste sem alargamento de contraste e com filtro de média 3x3	Média total	3975.17	372.83	1568.03	202.47	
	Desvio padrão	5759.91	361.34	2865.67	201.14	
Teste 4 - Teste sem alargamento de contraste e com filtro de mediana 3x3	Média total	4058.5	380.83	3112.1	204.84	
	Desvio padrão	5739.34	374.15	4416.28	208.41	
Teste 5 - Teste sem alargamento de contraste e sem filtros	Média total	4076.33	466.5	1624.84	256.16	
	Desvio padrão	5730.01	411.63	2854.34	234.9	
Bloco de testes 02: Testes Exame Completo						
Teste 1 - Teste exame completo com alargamento e sem filtros	Média total	2910.09	1442.28	2278.2	1019.16	
	Desvio padrão	1873.35	1158.93	1871.1	1032.9	
Teste 2 - Teste exame completo sem alargamento e sem filtros	Média total	8870.11	984.67	7419.2	757.07	
	Desvio padrão	9284.65	1426.26	8414.42	1366.64	

Fonte: autoria própria.

Foi possível observar que em média as áreas de lesões detectadas pela técnica MATLAB ACM foram maiores do que as áreas de lesões detectadas pela técnica ORACM, indicando que essa técnica apresentou uma resposta melhor na detecção de lesões. Porém, a técnica MATLAB ACM apresentou erros de detecção,

identificando o contorno externo dos pulmões ao invés das lesões, contabilizando uma área maior. Assim, mesmo que as médias do MATLAB ACM são maiores, não se pode afirmar que este método consegue detectar mais lesões.

Desse modo, também foram avaliados as médias e desvios padrão de todos os resultados para cada teste desconsiderando as fatias que apresentaram este erro de detecção, conforme a Tabela 10:

Tabela 10 - Média e desvio padrão de todas as fatias dos três exames para cada teste desconsiderando as fatias que apresentaram erro de detecção quando detecta o contorno externo dos pulmões ao invés das lesões

Média e desvio padrão de todos os resultados					
		Nº de pixels brancos		Área de lesões detectada (mm ²)	
		MATLAB ACM	ORACM	MATLAB ACM	ORACM
Considerando as fatias sem o erro de detecção quando detecta o contorno externo ao invés das lesões					
Bloco de Testes 01: Testes Preliminares					
Teste 1 - Teste com alargamento de contraste e filtro de média 3x3	Média total	1346	1414.75	712.48	751.44
	Desvio padrão	635.13	689.29	386.54	423.61
Teste 2 - Teste com alargamento de contraste e filtro de mediana 3x3	Média total	1277.25	1346.25	670.7	710.41
	Desvio padrão	605.71	643.02	347.53	380.95
Teste 3 - Teste sem alargamento de contraste e com filtro de média 3x3	Média total	496	539.75	265.49	289.26
	Desvio padrão	292.17	325.03	173.49	192.54
Teste 4 - Teste sem alargamento de contraste e com filtro de mediana 3x3	Média total	596.5	559.25	312.4	298.79
	Desvio padrão	294.56	324.96	163.55	192.06
Teste 5 - Teste sem alargamento de contraste e sem filtros	Média total	621.25	664	332.76	357.97
	Desvio padrão	322.46	352.69	203.29	222.77
Bloco de Testes 02: Testes Exame Completo					
Teste 1 - Teste exame completo com alargamento e sem filtros	Média total	1811.59	1846.37	1209.63	1210.94
	Desvio padrão	1396.49	1397.81	1349.47	1323.44
Teste 2 - Teste exame completo sem alargamento e sem filtros	Média total	1381.47	1354.36	1036.25	1018
	Desvio padrão	1842.58	1839.77	1813.15	1805.27

Fonte: autoria própria.

Sem contabilizar as áreas com erros, ocorridos na detecção feita pela técnica MATLAB ACM, as médias totais das áreas detectadas pelo ORACM foram um pouco maiores, para a maioria dos testes, indicando que esta técnica pode ter conseguido detectar mais lesões gerando menos erros, pois na Tabela 10, foram consideradas apenas as fatias consideradas com segmentação adequada (visualmente), e então ao se analisar os desvios padrões, pode-se concluir que, estatisticamente, as duas técnicas de segmentação apresentam resultados quantitativos bem parecidos, quando se desconsidera as fatias cuja segmentação por MATLAB ACM foram consideradas erradas. Somente no exame sem alargamento de contraste que a técnica MATLAB ACM obteve uma área maior do que o ORACM.

O mesmo ocorre quando se considera como métrica para avaliação quantitativa das técnicas de segmentação o número de pixels brancos.

6 DISCUSSÃO

Reunindo as informações, de forma geral, os dois métodos de contorno ativo, avaliados por este estudo, conseguiram detectar grande parte das lesões pulmonares na maioria das fatias testadas. Ainda, a área detectada pelas duas técnicas foi similar na maioria das fatias testadas, contudo, houve fatias que apresentaram erros de detecção.

Destes, ocorreram dois tipos principais: a extração errônea dos pulmões, faltando partes de lesões ou porções dos pulmões, e a detecção do contorno dos pulmões ao invés das lesões. Esta última falha ocorreu somente com o MATLAB ACM.

Com relação aos filtros, o filtro de média se apresentou mais eficaz do que o filtro de mediana por permitir a identificação de mais lesões. Contudo, nas imagens testadas, a não utilização dos filtros possibilitou uma detecção maior da área de lesões. Isso provavelmente ocorreu pelo efeito de borramento gerado pelos filtros de suavização.

Ainda, comparando-se as Tabelas 7 e 8, pode-se concluir que os dois métodos conseguem identificar mais lesões com a aplicação do alargamento de contraste. Entretanto, ao analisar os resultados do Apêndice pode-se notar que pedaços e porções que compreendem os pulmões foram eliminados de forma mais frequente nos testes com a aplicação do alargamento de contraste. Isso se deve à ampliação dos tons de cinza pelo alargamento de contraste, podendo gerar a junção de algumas

lesões com outros tecidos próximos aos pulmões, impedindo as técnicas de segmentar a área mais adequada.

Analisando as áreas obtidas, por meio da sintetização dos resultados utilizando-se a média total das áreas de cada teste realizado, obtemos que o MATLAB ACM apresentaria uma resposta melhor que o ORACM, entretanto, esta técnica apresentou erros de detecção das lesões que geraram áreas maiores que não condizem com as áreas de lesões. Analisando as áreas desconsiderando os exames que apresentaram estes erros, obtemos uma indicação de que o ORACM apresenta uma resposta melhor, por apresentar médias totais um pouco maiores e por apresentar menos erros.

Assim, pode-se concluir que, em suma, o método *Online region* ORACM apresentou um funcionamento melhor do que o MATLAB ACM *Sparse Field*. De fato, visualmente, na análise qualitativa, o ORACM conseguiu detectar mais lesões, obteve menos erros de detecção, além de ser um algoritmo mais rápido. Na análise quantitativa, se considerarmos os exames sem erros de segmentação das lesões, as médias totais do ORACM foram um pouco maiores, indicando uma detecção maior de lesões.

Vale ressaltar que, apesar do bom funcionamento do ORACM, esse método não conseguiu detectar todas as lesões presentes na imagem, além de contabilizar, em alguns casos, partes dos vasos sanguíneos como parte das lesões.

Com relação à interface, ela permitiu facilitar a interação do usuário com o código, permitindo salvar todas as imagens ou somente realizar uma visualização rápida para avaliação. Dessa forma, a interface permitiu tornar o programa compartilhável, entretanto, ainda demanda otimizações.

7 CONCLUSÃO

Como diversas doenças pulmonares pertencem ao ranking de causas globais de morte, o diagnóstico precoce é fundamental para reduzir a mortalidade dessas doenças. Uma forma de auxiliar o diagnóstico é a realização da segmentação das lesões pulmonares. A detecção digital dessas lesões facilita a visualização da região de interesse pelo radiologista, permitindo, também, melhor avaliar a progressão da doença.

A avaliação feita neste trabalho permite concluir, primeiramente, que o pré-processamento aplicado influencia os resultados de diferentes formas. De fato, após a comparação de diferentes pré-processamentos, verificou-se que os algoritmos MATLAB ACM e ORACM possuíram mais facilidade para detectar as lesões sem a aplicação de filtros de suavização e com a realização do alargamento de contraste.

Com relação à área de lesões detectadas pelos dois métodos, esta foi similar na maioria das fatias testadas, contudo, houve fatias que apresentaram erros de detecção. Em algumas imagens, ocorreu a extração errônea dos pulmões, faltando partes de lesões ou porções dos pulmões. Em outras, deu-se a detecção do contorno dos pulmões ao invés das lesões. Pôde-se notar que o erro de extração dos pulmões aconteceu em maior quantidade nos exames com alargamento de contraste. Já o segundo erro se deu apenas com a aplicação do MATLAB ACM.

Este segundo erro influenciou nos resultados quantitativos, que indicaram uma resposta melhor do MATLAB ACM. Porém, se desconsiderarmos as fatias que apresentaram esses erros, obtém-se uma indicação de que o ORACM apresenta uma resposta melhor, por apresentar médias totais um pouco maiores e por apresentar menos erros.

Ainda, concluiu-se que o método ORACM apresentou um funcionamento melhor do que o MATLAB ACM, já que conseguiu detectar mais lesões e obteve menos erros de detecção. Apesar disso, esse método não conseguiu detectar todas as lesões presentes na imagem.

Dessa forma, é necessário expandir a análise, avaliando outra estratégia para extração da área pulmonar, podendo-se realizar a segmentação do contorno externo antes da aplicação do alargamento de contraste e, após a aplicação deste, aplicar o método de contorno ativo para detecção das lesões. Além disso, pode-se avaliar

outras técnicas de segmentação e outras métricas além da área detectada, considerando a obtenção e comparação com o *gound of truth* dos exames.

Ainda, é interessante avaliar outros tipos de filtragem, permitindo alterar o pré-processamento, como também o pós-processamento das fatias que apresentarem erros, por meio da interface. Também é importante realizar os testes com todos os outros exames presentes na base de dados, analisando as diferenças de diversos pré-processamentos com imagens de diferentes qualidades e equipamentos.

REFERÊNCIAS

ABBOTT. **O que são infecções do trato respiratório e quais os tipos?**. [S. l.], 2021. Disponível em: <https://www.acare.com.br/pt/o-que-e-uma-infeccao-do-trato-respiratorio/>. Acesso em: 23 jul. 2022.

AKBARI, Younes *et al.* COVID-19 lesion segmentation using lung CT scan images: Comparative study based on active contour models. **Applied Sciences (Switzerland)**, [s. l.], v. 11, n. 17, 2021. Disponível em: <https://doi.org/10.3390/app11178039>

ALTA DIAGNÓSTICOS. **Tomografia computadorizada: Como funciona o exame?**. [S. l.], [s. d.]. Disponível em: <https://altadiagnosticos.com.br/saude/exames/tomografia-computadorizada>. Acesso em: 19 jun. 2022.

ANASTÁCIO, Rogério. **Segmentação e Volumetria Automática de Fígado a partir de Imagens Tomográficas**. 2015. - Universidade Federal de Uberlândia, [s. l.], 2015.

BERTUOL, Guilherme. **Análise e aplicação da técnica de contornos ativos com métodos de segmentação tradicionais em imagens médicas**. [s. l.], 2007. Disponível em: https://repositorio.ufsc.br/bitstream/handle/123456789/183970/monografia_guilherme_bertuol.pdf?sequence=-1

BEUTEL, J.; KUNDEL, H. L.; METTER, R. L. V. **Handbook of Medical Imaging**. Bellingham: SPIE Press, 2000.

CRÓSTA, Alvaro P. **Processamento digital de imagens de sensoriamento remoto**. Campinas: [s. n.], 1992.

DE ALEXANDRIA, Auzuir Ripardo *et al.* Método de contornos ativos psnakes aplicado em imagens de ecocardiograma de eixo curto para cálculo de fração de ejeção. **Revista Brasileira de Engenharia Biomedica**, [s. l.], v. 27, n. 3, p. 147–162, 2011. Disponível em: <https://doi.org/10.4322/rbeb.2011.012>

DOUCHERTY, Geoff. **Digital Image Processing for Medical Applications**. New York: Cambridge University Press, 2009.

DSOUZA, Cavin. **Contrast Stretching - File Exchange - MATLAB Central**. [S. l.], 2022. Disponível em: <https://fr.mathworks.com/matlabcentral/fileexchange/39910->

contrast-stretching. Acesso em: 14 jul. 2022.

EL REGAILY, S. *et al.* Lung Nodule Segmentation and Detection in CT. **Icicis 2017**, [s. l.], n. 8, p. 72–78, 2017.

FLETCHER, Jenna. **Lower respiratory tract infection: Symptoms, diagnosis, and treatment**. [S. l.], 2019. Disponível em: <https://www.medicalnewstoday.com/articles/324413#upper-vs-lower-respiratory-tract-infections>. Acesso em: 23 jul. 2022.

GONZALEZ, R. C.; WOODS, R. E. **Processamento digital de imagens**. São Paulo: Pearson Prentice Hall, 2010.

HATAMIZADEH, Ali *et al.* Deep Active Lesion Segmentation. **Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)**, [s. l.], v. 11861 LNCS, p. 98–105, 2019. Disponível em: https://doi.org/10.1007/978-3-030-32692-0_12. Acesso em: 17 dez. 2021.

HSIEH, J. **The computed tomograph principles, design, artifacts, and recent advances**. Bellingham: SPIE and Wiley-Interscience, 2009.

JOLLY, Marie-Pierre; GRADY, Leo. 3D GENERAL LESION SEGMENTATION IN CT. **Siemens Corporate Research**, [s. l.], p. 796–799, 2008.

KALRA, Anil. **Developing FE Human Models From Medical Images**. [S. l.]: Elsevier Inc., 2018. Disponível em: <https://doi.org/10.1016/B978-0-12-809831-8.00009-X>

KASS, M; WITKIN, A; TERZOPOULOS, D. Sankes: Active contour models. **International Journal of Computer Vision**, [s. l.], v. 1, n. 4, p. 321–331, 1987.

KROFT, Lucia J.M. *et al.* Added Value of Ultra–low-dose Computed Tomography, Dose Equivalent to Chest X-Ray Radiography, for Diagnosing Chest Pathology. **Journal of Thoracic Imaging**, [s. l.], v. 34, n. 3, p. 179, 2019. Disponível em: <https://doi.org/10.1097/RTI.0000000000000404>. Acesso em: 23 jul. 2022.

LANKTON, Shawn. Sparse Field Methods - Technical Report. **International Journal**, [s. l.], n. x, p. 1–8, 2009.

LAVANYA, M.; KANNAN, P. Muthu. Lung Lesion Detection in CT Scan Images Using the Fuzzy Local Information Cluster Means (FLICM) Automatic Segmentation

Algorithm and Back Propagation Network Classification. **Asian Pacific Journal of Cancer Prevention : APJCP**, [s. l.], v. 18, n. 12, p. 3395, 2017. Disponível em: <https://doi.org/10.22034/APJCP.2017.18.12.3395>. Acesso em: 17 dez. 2021.

MESQUITA, Vitor Alencar de. **CONTORNOS ATIVOS GEOMETRICOS E PARAMETRICOS APLICADOS À SEGMENTAÇÃO DO VENTRÍCULO ESQUERDO EM IMAGENS DE ECOCARDIOGRAFIA**. 2012. [s. l.], 2012.

MINISTÉRIO DA SAÚDE. **21/11 – Dia Mundial da Doença Pulmonar Obstrutiva Crônica – DPOC | Biblioteca Virtual em Saúde MS**. [S. l.], [s. d.]. Disponível em: <https://bvsms.saude.gov.br/21-11-dia-mundial-da-doenca-pulmonar-obstrutiva-cronica-dpoc/>. Acesso em: 23 jul. 2022.

NALBANDIAN, Ani *et al.* Post-acute COVID-19 syndrome. **Nature Medicine**, [s. l.], v. 27, n. 4, p. 601–615, 2021. Disponível em: <https://doi.org/10.1038/s41591-021-01283-z>

OULEFKI, Adel *et al.* Automatic COVID-19 lung infected region segmentation and measurement using CT-scans images. **Pattern Recognition**, [s. l.], v. 114, p. 107747, 2021. Disponível em: <https://doi.org/10.1016/j.patcog.2020.107747>

PRASAD, SHYAMA. **Digital Image Processing - Contrast enhancement Unit II**. [S. l.: s. n.], [s. d.]. Disponível em: <https://doi.org/10.1063/1.1683175>

RAJINIKANTH, Venkatesan *et al.* Firefly-Algorithm Supported Scheme to Detect COVID-19 Lesion in Lung CT Scan Images using Shannon Entropy and Markov-Random-Field. [s. l.], n. April, 2020. Disponível em: <http://arxiv.org/abs/2004.09239>

REBOUÇAS FILHO, Pedro Pedrosa. **MÉTODOS DE CONTORNOS ATIVOS CRISP ADAPTATIVO 2D E 3D APLICADOS NA SEGMENTAÇÃO DOS PULMÕES EM IMAGENS DE TOMOGRAFIA COMPUTADORIZADA DO TÓRAX**. 1–182 f. 2013. - Universidade Federal do Ceará, [s. l.], 2013.

SILVA, Ana Maria Marques da; PATROCÍNIO, Ana Cláudia; SCHIABEL, Homero. Processamento e Análise de Imagens Médicas Medical Image Processing and Analysis. [s. l.], v. 13, n. 1, p. 34–48, 2019.

SPRING. **Manuais Tutorial de Geoprocessamento - Processamento de Imagens**. [S. l.], 2006. Disponível em: http://www.dpi.inpe.br/spring/portugues/tutorial/introducao_pro.html. Acesso em: 16 jul. 2022.

TALU, M. Fatih. ORACM: Online region-based active contour model. **Expert**

Systems with Applications, [s. l.], v. 40, n. 16, p. 6233–6240, 2013. Disponível em: <https://doi.org/10.1016/j.eswa.2013.05.056>

WHITAKER, Ross T. A Level-Set Approach to 3D Reconstruction from Range Data. **International Journal of Computer Vision**, [s. l.], v. 29, n. 3, p. 203–231, 1998. Disponível em: <https://doi.org/10.1023/A:1008036829907>

WORLD HEALTH ORGANIZATION. **The top 10 causes of death**. [S. l.], 2020. Disponível em: <https://www.who.int/news-room/fact-sheets/detail/the-top-10-causes-of-death>. Acesso em: 23 jul. 2022.

WORLD HEALTH ORGANIZATION. **World health statistics 2021: monitoring health for the SDGs, sustainable development goals**. Geneva: [s. n.], 2021.

WORLD HEALTH ORGANIZATION. **World Health Statistics 2022: Monitoring health for the SDGs, sustainable development goals**. Geneva: [s. n.], 2022. Disponível em: <https://www.who.int/data/gho/publications/world-health-statistics>

YOUTUBE CHANNEL ELECTRICAL & COMPUTER ENGINEERING PROJECT. **Contrast stretching in MATLAB | Digital Image Processing-part 7**. [S. l.], 2021. Disponível em: <https://www.youtube.com/watch?v=8SiEmiGy6r8>. Acesso em: 12 maio 2022.

ZHAO, Chen *et al.* Lung segmentation and automatic detection of COVID-19 using radiomic features from chest CT images. **Pattern Recognition**, [s. l.], v. 119, p. 108071, 2021. Disponível em: <https://doi.org/10.1016/J.PATCOG.2021.108071>

ZHENG, Chuansheng *et al.* Deep Learning-based Detection for COVID-19 from Chest CT using Weak Label. **medRxiv**, [s. l.], 2020. Disponível em: <https://doi.org/10.1101/2020.03.12.20027185>. Acesso em: 17 dez. 2021.

APÊNDICE – RESULTADOS EXAMES COMPLETOS

Estão reunidos neste Apêndice, os resultados das áreas detectadas pelos dois métodos de contorno ativo avaliados neste estudo para os três exames completos.

A Tabela I reúne os dados obtidos para a avaliação com alargamento de contraste, sem a aplicação de filtros. A Tabela II reúne os resultados obtidos para a avaliação sem alargamento de contraste e sem filtros.

A área detectada pelas duas técnicas foi similar na maioria das fatias testadas, contudo, houve fatias que apresentaram erros de detecção. Estas estão destacadas em vermelho ou azul.

Os destaques em vermelho referem-se a erros na detecção de lesões quando a técnica detecta o contorno externo dos pulmões ao invés de detectar as lesões, gerando uma área maior e errônea. Em todos os casos que isso ocorreu, a técnica MATLAB ACM detectou apenas as bordas dos pulmões, enquanto a técnica ORACM detectou as lesões pulmonares.

Os destaques em azul referem-se a erros gerados pela extração dos pulmões em que partes que compreendem os pulmões foram eliminadas. Pode-se notar que esse erro aconteceu mais vezes no teste com aplicação do alargamento de contraste, dificultando a separação das partes que são pulmão das que não são. Entretanto, os outros testes verificaram que com a aplicação do alargamento de contraste, as duas metodologias de contornos ativos conseguem detectar melhor as pequenas lesões pulmonares.

Ainda, as linhas preenchidas com a cor cinza indicam as fatias que foram analisadas na seção Resultados deste trabalho.

Todas as imagens obtidas para a realização das análises podem ser encontradas no repositório acessado pelo link: https://1drv.ms/u/s!AhJ6kJQi6q_46QC2llex_pQT2Flu?e=dImKW3

Tabela I - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste com aplicação do alargamento de contraste e sem filtros nos três exames completos (continua)

Teste com alargamento de contraste sem filtros				
Fatia	Nº de pixels brancos		Área de lesões detectada (mm ²)	
	MATLAB ACM	ORACM	MATLAB ACM	ORACM
Exame 9a_siemens_modiCASGMBH_2mm				
60	2198	773	1003.78	353.01
61	736	785	336.12	358.49
62	751	797	342.97	363.97
63	791	825	361.23	376.76
64	765	806	349.36	368.08
65	808	834	369	380.87
66	846	869	386.35	396.86
67	903	928	412.38	423.8
68	866	893	395.49	407.82
69	897	918	409.64	419.23
70	961	983	438.87	448.92
71	1006	1039	459.42	474.49
72	1067	1098	487.28	501.43
73	1027	1060	469.01	484.08
74	1170	1198	534.32	547.1
75	1237	1247	564.91	569.48
76	1185	1201	541.17	548.47
77	1216	1268	555.32	579.07
78	1291	1310	589.57	598.25
79	1392	1383	635.7	631.59
80	1424	1454	650.31	664.01
81	1469	1494	670.86	682.28
82	1474	1487	673.15	679.08
83	1565	1568	714.7	716.07
84	1230	1249	561.72	570.39
85	1416	1418	646.66	647.57
86	1249	1258	570.39	574.5
87	1470	1481	671.32	676.34
88	1247	1265	569.48	577.7
89	858	874	391.83	399.14
90	841	859	384.07	392.29

Tabela II - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste com aplicação do alargamento de contraste e sem filtros nos três exames completos (continua)

Teste com alargamento de contraste sem filtros				
Fatia	Nº de pixels brancos		Área de lesões detectada (mm ²)	
	MATLAB ACM	ORACM	MATLAB ACM	ORACM
Exame 9a_siemens_modiCASGMBH_2mm				
91	842	873	384.52	398.68
92	675	716	308.26	326.98
93	604	641	275.83	292.73
94	730	772	333.38	352.56
95	670	698	305.98	318.76
96	741	780	338.4	356.21
97	854	888	390	405.53
98	777	785	354.84	358.49
99	822	873	375.39	398.68
100	800	818	365.34	373.56
101	930	964	424.71	440.24
102	1001	1037	457.14	473.58
103	1316	1347	600.99	615.15
104	1239	1276	565.83	582.72
105	1107	1131	505.55	516.51
106	1037	1074	473.58	490.47
107	984	1004	449.37	458.51
108	1205	1203	550.3	549.39
109	1031	1001	470.84	457.14
110	1487	1423	679.08	649.86
111	1246	1261	569.02	575.87
112	1248	1271	569.94	580.44
113	1316	1352	600.99	617.43
114	1660	1714	758.09	782.75
115	1592	1657	727.04	756.72
116	1491	1542	680.91	704.2
117	1502	1480	685.93	675.89
118	1488	1431	679.54	653.51
119	1257	1285	574.05	586.83
120	882	920	402.79	420.15
121	1146	1174	523.36	536.14

Tabela III - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste com aplicação do alargamento de contraste e sem filtros nos três exames completos (continua)

Teste com alargamento de contraste sem filtros				
Fatia	Nº de pixels brancos		Área de lesões detectada (mm ²)	
	MATLAB ACM	ORACM	MATLAB ACM	ORACM
Exame 9a_siemens_modiCASGMBH_2mm				
122	841	832	384.07	379.96
123	1100	1121	502.35	511.94
124	909	945	415.12	431.56
125	1094	1115	499.61	509.2
126	1335	1375	609.67	627.94
127	1281	1311	585.01	598.71
128	1124	1174	513.31	536.14
129	1159	1226	529.29	559.89
130	1194	1264	545.28	577.24
131	1320	1390	602.82	634.79
132	968	1017	442.07	464.44
133	1451	1479	662.64	675.43
134	1279	1314	584.09	600.08
135	965	1026	440.7	468.55
136	1232	1295	562.63	591.4
137	1114	1196	508.74	546.19
138	983	1057	448.92	482.71
139	969	1037	442.52	473.58
140	895	926	408.73	422.89
141	1112	1165	507.83	532.03
142	1360	1420	621.09	648.49
143	1756	1830	801.93	835.72
144	1746	1854	797.36	846.69
145	1634	1707	746.22	779.55
146	1596	1646	728.86	751.7
147	1421	1548	648.94	706.94
148	1570	1636	716.99	747.13
149	1743	1884	795.99	860.39
150	1461	1576	667.21	719.73
151	1709	1834	780.47	837.55
152	1546	1697	706.03	774.99

Tabela IV - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste com aplicação do alargamento de contraste e sem filtros nos três exames completos (continua)

Teste com alargamento de contraste sem filtros				
Fatia	Nº de pixels brancos		Área de lesões detectada (mm ²)	
	MATLAB ACM	ORACM	MATLAB ACM	ORACM
Exame 9a_siemens_modiCASGMBH_2mm				
153	2987	3114	1364.1	1422.1
154	2744	2829	1253.13	1291.95
155	3850	3948	1758.22	1802.97
156	3835	3973	1751.37	1814.39
157	3817	3934	1743.15	1796.58
158	3648	3744	1665.97	1709.81
159	3372	3412	1539.93	1558.19
160	3112	3168	1421.19	1446.76
161	3057	3106	1396.07	1418.45
162	3084	3142	1408.4	1434.89
163	2941	3008	1343.1	1373.69
164	2732	2783	1247.65	1270.94
165	2457	2582	1122.06	1179.15
166	2574	2682	1175.5	1224.82
167	2622	2742	1197.42	1252.22
168	2556	2658	1167.27	1213.86
169	2470	2606	1128	1190.11
170	2332	2444	1064.98	1116.13
171	2194	2308	1001.96	1054.02
172	2261	2357	1032.55	1076.4
173	2293	2408	1047.17	1099.69
174	2195	2344	1002.41	1070.46
175	2247	2417	1026.16	1103.8
176	2306	2517	1053.1	1149.46
177	2218	2436	1012.92	1112.47
178	2288	2465	1044.88	1125.72
179	2415	2582	1102.88	1179.15
180	2556	2738	1167.27	1250.39
181	2468	2678	1127.09	1222.99
182	2372	2617	1083.25	1195.13
183	2547	2804	1163.16	1280.53

Tabela I - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste com aplicação do alargamento de contraste e sem filtros nos três exames completos (continua)

Teste com alargamento de contraste sem filtros				
Fatia	Nº de pixels brancos		Área de lesões detectada (mm ²)	
	MATLAB ACM	ORACM	MATLAB ACM	ORACM
Exame 9a_siemens_modiCASGMBH_2mm				
184	2680	2898	1223.9	1323.46
185	2409	2698	1100.14	1232.12
186	2311	2625	1055.39	1198.79
187	2266	2556	1034.84	1167.27
188	2304	2554	1052.19	1166.36
189	2246	2448	1025.7	1117.95
190	2208	2374	1008.35	1084.16
191	2262	2397	1033.01	1094.66
192	2260	2446	1032.1	1117.04
193	2208	2392	1008.35	1092.38
194	2156	2313	984.6	1056.3
195	2104	2356	960.86	1075.94
196	2066	2362	943.5	1078.68
197	2138	2423	976.38	1106.54
198	1673	2244	764.03	1024.79
199	1560	2093	712.42	955.83
200	1565	2153	714.7	983.23
201	1705	2242	778.64	1023.88
202	1767	2059	806.95	940.3
203	1180	1449	538.88	661.73
204	1156	1451	527.92	662.64
205	2871	3249	1311.13	1483.75
206	1237	1487	564.91	679.08
Exame 10a_siemens_modiCASGMBH_2mm				
68	4060	414	2863.67	292.01
69	4012	444	2829.81	313.17
70	3968	492	2798.78	347.03
71	4035	479	2846.04	337.86
72	4130	485	2913.04	342.09
73	4127	536	2910.93	378.06

Tabela V - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste com aplicação do alargamento de contraste e sem filtros nos três exames completos (continua)

Teste com alargamento de contraste sem filtros				
Fatia	Nº de pixels brancos		Área de lesões detectada (mm ²)	
	MATLAB ACM	ORACM	MATLAB ACM	ORACM
Exame 10a_siemens_modiCASGMBH_2mm				
74	4064	534	2866.49	376.65
75	4146	543	2924.33	383
76	4217	553	2974.41	390.05
77	4602	578	3245.96	407.69
78	4957	632	3496.36	445.77
79	5223	794	3683.98	560.04
80	5377	879	3792.6	619.99
81	5459	836	3850.44	589.66
82	5541	855	3908.28	603.06
83	5484	961	3868.07	677.83
84	5405	1064	3812.35	750.48
85	2751	857	1940.38	604.47
86	2655	822	1872.67	579.79
87	2485	696	1752.76	490.91
88	2539	669	1790.85	471.87
89	2608	709	1839.52	500.08
90	2631	709	1855.74	500.08
91	2547	719	1796.49	507.14
92	2463	728	1737.25	513.49
93	2581	783	1820.48	552.28
94	2722	644	1919.93	454.24
95	3157	818	2226.75	576.97
96	3424	1070	2415.08	754.71
97	3824	1262	2697.21	890.14
98	4015	1224	2831.93	863.33
99	3867	1108	2727.54	781.51
100	3714	1082	2619.62	763.18
101	3556	1109	2508.18	782.22
102	3343	1080	2357.94	761.76
103	3202	1059	2258.49	746.95
104	3054	1045	2154.1	737.08

Tabela VI - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste com aplicação do alargamento de contraste e sem filtros nos três exames completos (continua)

Teste com alargamento de contraste sem filtros				
Fatia	Nº de pixels brancos		Área de lesões detectada (mm ²)	
	MATLAB ACM	ORACM	MATLAB ACM	ORACM
Exame 10a_siemens_modiCASGMBH_2mm				
105	3196	1090	2254.26	768.82
106	3422	1192	2413.67	840.76
107	3554	1296	2506.77	914.12
108	3610	1391	2546.27	981.12
109	3531	1352	2490.55	953.62
110	3618	1477	2551.91	1041.78
111	2897	821	2043.36	579.08
112	3217	953	2269.07	672.19
113	3371	969	2377.69	683.47
114	3520	1105	2482.79	779.4
115	3135	771	2211.23	543.82
116	3389	819	2390.39	577.67
117	3423	854	2414.37	602.36
118	3576	938	2522.29	661.61
119	3618	989	2551.91	697.58
120	3732	1030	2632.32	726.5
121	3449	772	2432.71	544.52
122	3322	778	2343.13	548.75
123	3395	902	2394.62	636.21
124	3149	869	2221.11	612.94
125	3435	1076	2422.83	758.94
126	3558	1169	2509.59	824.54
127	3465	1048	2443.99	739.19
128	3579	1045	2524.4	737.08
129	3941	1317	2779.74	928.93
130	3914	1272	2760.69	897.19
131	3873	1339	2731.77	944.45
132	3913	1375	2759.99	969.84
133	3813	1228	2689.45	866.15
134	4067	1341	2868.61	945.86
135	3940	1164	2779.03	821.01

Tabela VII - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste com aplicação do alargamento de contraste e sem filtros nos três exames completos (continua)

Teste com alargamento de contraste sem filtros				
Fatia	Nº de pixels brancos		Área de lesões detectada (mm ²)	
	MATLAB ACM	ORACM	MATLAB ACM	ORACM
Exame 10a_siemens_modiCASGMBH_2mm				
136	3996	1037	2818.53	731.44
137	4286	1187	3023.08	837.24
138	4294	1315	3028.72	927.52
139	3878	1093	2735.3	770.93
140	3788	981	2671.82	691.94
141	3836	825	2705.67	581.9
142	4052	898	2858.03	633.39
143	3828	853	2700.03	601.65
144	3752	897	2646.43	632.69
145	3915	998	2761.4	703.93
146	4270	1237	3011.79	872.5
147	4273	1294	3013.91	912.71
148	4208	1228	2968.06	866.15
149	4742	1689	3344.71	1191.32
150	4510	1513	3181.07	1067.18
151	4388	1456	3095.02	1026.97
152	4264	1257	3007.56	886.61
153	4131	1064	2913.75	750.48
154	4252	1067	2999.1	752.6
155	4457	1057	3143.69	745.54
156	4472	1042	3154.27	734.96
157	4799	1253	3384.91	883.79
158	4923	1448	3472.38	1021.33
159	4242	942	2992.04	664.43
160	3995	868	2817.82	612.23
161	4202	1196	2963.83	843.58
162	3872	1088	2731.07	767.41
163	3805	996	2683.81	702.52
164	4945	1998	3487.89	1409.26
165	4934	1852	3480.14	1306.29
166	4577	1624	3228.33	1145.47

Tabela VIII - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste com aplicação do alargamento de contraste e sem filtros nos três exames completos (continua)

Teste com alargamento de contraste sem filtros				
Fatia	Nº de pixels brancos		Área de lesões detectada (mm ²)	
	MATLAB ACM	ORACM	MATLAB ACM	ORACM
Exame 10a_siemens_modiCASGMBH_2mm				
167	4126	1355	2910.22	955.73
168	4176	1288	2945.49	908.47
169	4250	1178	2997.68	830.89
170	4218	1103	2975.11	777.99
171	4285	1063	3022.37	749.77
172	4270	1012	3011.79	713.8
173	4418	999	3116.18	704.63
174	1164	1235	821.01	871.09
175	1258	1320	887.31	931.05
176	2351	2430	1658.25	1713.97
177	2054	2093	1448.76	1476.27
178	2036	2115	1436.07	1491.79
179	2004	2105	1413.5	1484.74
180	1869	1937	1318.28	1366.24
181	1751	1807	1235.05	1274.54
182	1632	1682	1151.11	1186.38
183	3234	3254	2281.06	2295.17
184	3028	3086	2135.76	2176.67
185	2780	2881	1960.84	2032.08
186	2581	2753	1820.48	1941.79
187	2505	2587	1766.87	1824.71
188	2391	2541	1686.46	1792.26
189	2467	2574	1740.07	1815.54
190	2545	2626	1795.08	1852.22
191	2386	2560	1682.94	1805.66
192	2274	2423	1603.94	1709.03
193	2818	2917	1987.64	2057.47
194	3659	3793	2580.83	2675.35
195	2003	2178	1412.79	1536.23
196	1859	2094	1311.22	1476.98
197	1753	1903	1236.46	1342.26

Tabela I- Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste com aplicação do alargamento de contraste e sem filtros nos três exames completos (continua)

Teste com alargamento de contraste sem filtros				
Fatia	Nº de pixels brancos		Área de lesões detectada (mm ²)	
	MATLAB ACM	ORACM	MATLAB ACM	ORACM
Exame 10a_siemens_modiCASGMBH_2mm				
198	1714	1916	1208.95	1351.43
199	1639	1808	1156.05	1275.25
200	1552	1725	1094.68	1216.71
201	1401	1589	988.18	1120.78
202	1326	1483	935.28	1046.02
203	1309	1497	923.29	1055.89
204	1258	1438	887.31	1014.28
205	1158	1285	816.78	906.36
206	1135	1249	800.56	880.97
207	1122	1254	791.39	884.49
208	1096	1231	773.05	868.27
209	1321	1449	931.75	1022.03
210	1072	1170	756.12	825.24
211	1063	1143	749.77	806.2
212	1007	1120	710.27	789.98
213	899	969	634.1	683.47
214	774	820	545.93	578.38
215	786	852	554.4	600.95
216	773	821	545.23	579.08
217	772	807	544.52	569.21
218	658	707	464.11	498.67
219	678	766	478.22	540.29
220	657	736	463.41	519.13
221	573	656	404.16	462.7
222	470	537	331.51	378.77
223	413	456	291.3	321.63
224	393	454	277.2	320.22
225	432	463	304.71	326.57
226	449	482	316.7	339.97
227	375	426	264.5	300.47
228	332	369	234.17	260.27

Tabela IX - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste com aplicação do alargamento de contraste e sem filtros nos três exames completos (continua)

Teste com alargamento de contraste sem filtros				
Fatia	Nº de pixels brancos		Área de lesões detectada (mm ²)	
	MATLAB ACM	ORACM	MATLAB ACM	ORACM
Exame 10a_siemens_modiCASGMBH_2mm				
229	306	338	215.83	238.4
230	256	297	180.57	209.49
231	1712	266	1207.54	187.62
232	1629	239	1148.99	168.58
233	1666	230	1175.09	162.23
234	1637	259	1154.64	182.68
235	1513	224	1067.18	158
Exame 11a_siemens_modiCASGMBH_2mm				
71	1754	115	1672.74	109.67
72	1835	136	1749.99	129.7
73	1875	163	1788.14	155.45
74	1951	205	1860.62	195.5
75	1952	200	1861.57	190.73
76	1862	201	1775.74	191.69
77	1790	215	1707.08	205.04
78	1743	196	1662.25	186.92
79	1878	194	1791	185.01
80	2056	217	1960.75	206.95
81	2165	257	2064.7	245.09
82	2261	310	2156.26	295.64
83	2333	323	2224.92	308.04
84	2517	327	2400.4	311.85
85	2812	333	2681.73	317.57
86	3030	391	2889.63	372.89
87	3112	451	2967.83	430.11
88	3198	510	3049.85	486.37
89	3341	625	3186.23	596.05
90	3610	706	3442.76	673.29
91	3577	672	3411.29	640.87
92	3733	676	3560.07	644.68

Tabela X - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste com aplicação do alargamento de contraste e sem filtros nos três exames completos (continua)

Teste com alargamento de contraste sem filtros				
Fatia	Nº de pixels brancos		Área de lesões detectada (mm ²)	
	MATLAB ACM	ORACM	MATLAB ACM	ORACM
Exame 11a_siemens_modiCASGMBH_2mm				
93	3759	690	3584.86	658.04
94	3852	711	3673.55	678.06
95	3953	761	3769.87	725.75
96	3943	724	3760.34	690.46
97	3926	729	3744.13	695.23
98	3931	725	3748.89	691.41
99	4094	758	3904.34	722.89
100	4190	693	3995.9	660.9
101	4344	809	4142.76	771.52
102	4374	777	4171.37	741
103	4317	778	4117.01	741.96
104	4409	932	4204.75	888.82
105	4451	960	4244.8	915.53
106	4415	992	4210.47	946.04
107	4588	1139	4375.46	1086.24
108	4646	1153	4430.77	1099.59
109	4736	1102	4516.6	1050.95
110	4660	1062	4444.12	1012.8
111	4633	944	4418.37	900.27
112	4556	960	4344.94	915.53
113	4738	1048	4518.51	999.45
114	4846	1059	4621.51	1009.94
115	4927	1034	4698.75	986.1
116	5035	1049	4801.75	1000.4
117	5198	1092	4957.2	1041.41
118	5180	1222	4940.03	1165.39
119	5189	1358	4948.62	1295.09
120	5054	1358	4819.87	1295.09
121	4807	1249	4584.31	1191.14
122	4856	1166	4631.04	1111.98
123	4971	1180	4740.72	1125.34

Tabela XI - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste com aplicação do alargamento de contraste e sem filtros nos três exames completos (continua)

Teste com alargamento de contraste sem filtros				
Fatia	Nº de pixels brancos		Área de lesões detectada (mm ²)	
	MATLAB ACM	ORACM	MATLAB ACM	ORACM
Exame 11a_siemens_modiCASGMBH_2mm				
124	5136	1214	4898.07	1157.76
125	5382	1254	5132.68	1195.91
126	5484	1279	5229.95	1219.75
127	5507	1296	5251.88	1235.96
128	5679	1449	5415.92	1381.87
129	5839	1514	5568.5	1443.86
130	6285	1708	5993.84	1628.88
131	6773	1963	6459.24	1872.06
132	7129	2240	6798.74	2136.23
133	7442	2457	7097.24	2343.18
134	7318	2428	6978.99	2315.52
135	6811	2009	6495.48	1915.93
136	7277	2109	6939.89	2011.3
137	7556	2027	7205.96	1933.1
138	7624	2033	7270.81	1938.82
139	7078	1354	6750.11	1291.28
140	7254	1416	6917.95	1350.4
141	7106	1447	6776.81	1379.97
142	6838	1282	6521.22	1222.61
143	6555	950	6251.34	905.99
144	6696	925	6385.8	882.15
145	6904	846	6584.17	806.81
146	7441	1113	7096.29	1061.44
147	7427	1120	7082.94	1068.12
148	7417	1181	7073.4	1126.29
149	7462	1259	7116.32	1200.68
150	8053	1394	7679.94	1329.42
151	6735	1127	6423	1074.79
152	6730	994	6418.23	947.95
153	8077	1320	7702.83	1258.85
154	8094	1238	7719.04	1180.65

Tabela XII - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste com aplicação do alargamento de contraste e sem filtros nos três exames completos (continua)

Teste com alargamento de contraste sem filtros				
Fatia	Nº de pixels brancos		Área de lesões detectada (mm ²)	
	MATLAB ACM	ORACM	MATLAB ACM	ORACM
Exame 11a_siemens_modiCASGMBH_2mm				
155	7929	1155	7561.68	1101.49
156	7494	1034	7146.84	986.1
157	6881	913	6562.23	870.7
158	6605	900	6299.02	858.31
159	3748	792	3574.37	755.31
160	3855	868	3676.41	827.79
161	3955	607	3771.78	578.88
162	4887	799	4660.61	761.99
163	3742	822	3568.65	783.92
164	3522	614	3358.84	585.56
165	3804	542	3627.78	516.89
166	3950	745	3767.01	710.49
167	3904	915	3723.14	872.61
168	3429	831	3270.15	792.5
169	4535	603	4324.91	575.07
170	3856	517	3677.37	493.05
171	4052	542	3864.29	516.89
172	4279	715	4080.77	681.88
173	4405	950	4200.94	905.99
174	4988	965	4756.93	920.3
175	4604	841	4390.72	802.04
176	3769	541	3594.4	515.94
177	3949	667	3766.06	636.1
178	654	631	623.7	601.77
179	738	672	703.81	640.87
180	778	764	741.96	728.61
181	1188	1181	1132.97	1126.29
182	819	830	781.06	791.55
183	801	793	763.89	756.26
184	1109	1048	1057.62	999.45
185	1271	1120	1212.12	1068.12

Tabela XIII - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste com aplicação do alargamento de contraste e sem filtros nos três exames completos (continua)

Teste com alargamento de contraste sem filtros				
Fatia	Nº de pixels brancos		Área de lesões detectada (mm ²)	
	MATLAB ACM	ORACM	MATLAB ACM	ORACM
Exame 11a_siemens_modiCASGMBH_2mm				
186	1398	1189	1333.24	1133.92
187	2481	703	2366.07	670.43
188	1812	1141	1728.06	1088.14
189	1180	1171	1125.34	1116.75
190	1203	1166	1147.27	1111.98
191	1931	1644	1841.55	1567.84
192	1747	1491	1666.07	1421.93
193	1180	1193	1125.34	1137.73
194	1164	1140	1110.08	1087.19
195	1164	1095	1110.08	1044.27
196	1321	1232	1259.8	1174.93
197	1322	1222	1260.76	1165.39
198	1621	1585	1545.91	1511.57
199	2247	1876	2142.91	1789.09
200	1848	1778	1762.39	1695.63
201	2238	2064	2134.32	1968.38
202	2725	2668	2598.76	2544.4
203	2285	2281	2179.15	2175.33
204	2016	1976	1922.61	1884.46
205	2671	2001	2547.26	1908.3
206	1603	1555	1528.74	1482.96
207	1788	1742	1705.17	1661.3
208	2684	1262	2559.66	1203.54
209	1519	1390	1448.63	1325.61
210	3002	1611	2862.93	1536.37
211	1957	1889	1866.34	1801.49
212	2685	2629	2560.62	2507.21
213	4402	3419	4198.07	3260.61
214	4000	3980	3814.7	3795.62
215	4529	4447	4319.19	4240.99
216	5008	4780	4776	4558.56

Tabela XIV - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste com aplicação do alargamento de contraste e sem filtros nos três exames completos (conclusão)

Teste com alargamento de contraste sem filtros				
Fatia	Nº de pixels brancos		Área de lesões detectada (mm ²)	
	MATLAB ACM	ORACM	MATLAB ACM	ORACM
Exame 11a_siemens_modiCASGMBH_2mm				
217	5004	5030	4772.19	4796.98
218	5050	5078	4816.06	4842.76
219	5507	5521	5251.88	5265.24
220	6045	6067	5764.96	5785.94
221	6295	6316	6003.38	6023.41
222	1496	1476	1426.7	1407.62
223	1614	1592	1539.23	1518.25
224	1881	1891	1793.86	1803.4
225	2393	1933	2282.14	1843.45
226	2343	2323	2234.46	2215.39
227	3238	2879	3088	2745.63
228	3200	3239	3051.76	3088.95
229	3780	3788	3604.89	3612.52
230	12168	12226	11604.31	11659.62
231	12784	12805	12191.77	12211.8
232	4890	4895	4663.47	4668.24
233	5201	5144	4960.06	4905.7
234	786	765	749.59	729.56
235	654	573	623.7	546.46
236	531	469	506.4	447.27
237	598	560	570.3	534.06
238	698	698	665.66	665.66
239	611	614	582.7	585.56
240	413	395	393.87	376.7
241	569	555	542.64	529.29
242	509	478	485.42	455.86
243	1983	420	1891.14	400.54
244	1961	396	1870.16	377.66
245	1880	391	1792.91	372.89
246	1760	408	1678.47	389.1

Fonte: autoria própria.

Tabela II - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste com aplicação do alargamento de contraste e sem filtros nos três exames completos (continua)

Teste sem alargamento de contraste sem filtros				
Fatia	Nº de pixels brancos		Área de lesões detectada (mm ²)	
	MATLAB ACM	ORACM	MATLAB ACM	ORACM
Exame 9a_siemens_modiCASGMBH_2mm				
60	14523	244	6632.37	111.43
61	234	258	106.86	117.82
62	270	285	123.3	130.15
63	286	295	130.61	134.72
64	254	269	116	122.85
65	301	310	137.46	141.57
66	327	342	149.33	156.18
67	317	337	144.77	153.9
68	326	333	148.88	152.07
69	323	338	147.51	154.36
70	373	378	170.34	172.63
71	402	415	183.59	189.52
72	406	411	185.41	187.7
73	425	438	194.09	200.03
74	462	473	210.99	216.01
75	499	508	227.88	231.99
76	492	516	224.69	235.65
77	550	563	251.17	257.11
78	547	558	249.8	254.83
79	694	707	316.94	322.87
80	703	716	321.05	326.98
81	725	740	331.09	337.94
82	735	747	335.66	341.14
83	769	777	351.19	354.84
84	854	881	390	402.34
85	731	748	333.83	341.6
86	886	905	404.62	413.3
87	675	685	308.26	312.83
88	730	732	333.38	334.29
89	724	732	330.64	334.29
90	490	492	223.77	224.69

Tabela II - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste com aplicação do alargamento de contraste e sem filtros nos três exames completos (continua)

Teste sem alargamento de contraste sem filtros				
Fatia	Nº de pixels brancos		Área de lesões detectada (mm ²)	
	MATLAB ACM	ORACM	MATLAB ACM	ORACM
Exame 9a_siemens_modiCASGMBH_2mm				
91	381	393	174	179.48
92	930	355	424.71	162.12
93	309	270	141.11	123.3
94	165	172	75.35	78.55
95	215	217	98.19	99.1
96	209	217	95.45	99.1
97	240	246	109.6	112.34
98	277	282	126.5	128.78
99	436	385	199.11	175.82
100	337	352	153.9	160.75
101	379	384	173.08	175.37
102	559	566	255.28	258.48
103	1102	643	503.26	293.65
104	788	460	359.86	210.07
105	875	545	399.6	248.89
106	776	413	354.38	188.61
107	854	472	390	215.55
108	918	498	419.23	227.43
109	1103	431	503.72	196.83
110	1255	548	573.13	250.26
111	1263	556	576.79	253.91
112	1150	472	525.18	215.55
113	1199	568	547.56	259.39
114	1275	690	582.27	315.11
115	1251	721	571.31	329.27
116	1180	692	538.88	316.02
117	1239	711	565.83	324.7
118	1064	608	485.91	277.66
119	628	482	286.8	220.12
120	577	458	263.5	209.16
121	704	594	321.5	271.27

Tabela II - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste com aplicação do alargamento de contraste e sem filtros nos três exames completos (continua)

Teste sem alargamento de contraste sem filtros				
Fatia	Nº de pixels brancos		Área de lesões detectada (mm ²)	
	MATLAB ACM	ORACM	MATLAB ACM	ORACM
Exame 9a_siemens_modiCASGMBH_2mm				
122	724	534	330.64	243.87
123	730	572	333.38	261.22
124	733	610	334.75	278.57
125	805	513	367.63	234.28
126	444	465	202.77	212.36
127	467	495	213.27	226.06
128	525	543	239.76	247.98
129	481	507	219.66	231.54
130	475	511	216.92	233.36
131	545	558	248.89	254.83
132	602	625	274.92	285.43
133	584	610	266.7	278.57
134	730	755	333.38	344.79
135	801	845	365.8	385.89
136	783	815	357.58	372.19
137	658	686	300.5	313.28
138	320	346	146.14	158.01
139	386	380	176.28	173.54
140	614	641	280.4	292.73
141	686	712	313.28	325.16
142	916	931	418.32	425.17
143	977	1012	446.18	462.16
144	923	958	421.52	437.5
145	920	953	420.15	435.22
146	838	865	382.7	395.03
147	791	820	361.23	374.48
148	688	725	314.2	331.09
149	784	813	358.04	371.28
150	810	845	369.91	385.89
151	1262	1213	576.33	553.95
152	1718	1639	784.58	748.5

Tabela II - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste com aplicação do alargamento de contraste e sem filtros nos três exames completos (continua)

Teste sem alargamento de contraste sem filtros				
Fatia	Nº de pixels brancos		Área de lesões detectada (mm ²)	
	MATLAB ACM	ORACM	MATLAB ACM	ORACM
Exame 9a_siemens_modiCASGMBH_2mm				
153	1782	1822	813.8	832.07
154	2327	2265	1062.7	1034.38
155	2231	2296	1018.85	1048.54
156	2358	2325	1076.85	1061.78
157	2467	2350	1126.63	1073.2
158	2105	2175	961.31	993.28
159	1786	1836	815.63	838.47
160	1680	1748	767.22	798.28
161	1685	1781	769.51	813.35
162	1714	1786	782.75	815.63
163	1600	1643	730.69	750.33
164	1385	1431	632.5	653.51
165	1281	1340	585.01	611.95
166	1268	1301	579.07	594.14
167	1254	1300	572.68	593.68
168	1292	1350	590.03	616.52
169	1182	1233	539.8	563.09
170	1137	1186	519.25	541.62
171	1110	1152	506.92	526.1
172	1110	1159	506.92	529.29
173	1164	1223	531.58	558.52
174	1126	1185	514.22	541.17
175	1063	1145	485.45	522.9
176	1085	1158	495.5	528.84
177	1118	1168	510.57	533.4
178	1136	1167	518.79	532.95
179	1140	1187	520.62	542.08
180	1169	1223	533.86	558.52
181	1119	1181	511.03	539.34
182	1104	1172	504.18	535.23
183	1074	1143	490.47	521.99

Tabela II - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste com aplicação do alargamento de contraste e sem filtros nos três exames completos (continua)

Teste sem alargamento de contraste sem filtros				
Fatia	Nº de pixels brancos		Área de lesões detectada (mm ²)	
	MATLAB ACM	ORACM	MATLAB ACM	ORACM
Exame 9a_siemens_modiCASGMBH_2mm				
184	1100	1168	502.35	533.4
185	1028	1117	469.47	510.11
186	997	1091	455.31	498.24
187	1014	1097	463.07	500.98
188	918	1023	419.23	467.18
189	912	966	416.49	441.15
190	924	975	421.97	445.26
191	975	1040	445.26	474.95
192	1001	1076	457.14	491.39
193	935	1036	427	473.12
194	924	1010	421.97	461.25
195	913	1018	416.95	464.9
196	833	915	380.41	417.86
197	645	851	294.56	388.63
198	610	774	278.57	353.47
199	585	747	267.16	341.14
200	671	819	306.43	374.02
201	762	921	347.99	420.6
202	863	1058	394.12	483.17
203	1118	1225	510.57	559.43
204	1359	1463	620.63	668.12
205	1877	2017	857.19	921.12
206	2534	2660	1157.23	1214.77
Exame 10a_siemens_modiCASGMBH_2mm				
68	14196	126	10012.97	88.87
69	14614	152	10307.8	107.21
70	15105	175	10654.12	123.43
71	15599	189	11002.56	133.31
72	16037	183	11311.5	129.08
73	16509	203	11644.42	143.18

Tabela II - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste com aplicação do alargamento de contraste e sem filtros nos três exames completos (continua)

Teste sem alargamento de contraste sem filtros				
Fatia	Nº de pixels brancos		Área de lesões detectada (mm ²)	
	MATLAB ACM	ORACM	MATLAB ACM	ORACM
Exame 10a_siemens_modiCASGMBH_2mm				
74	16964	226	11965.35	159.41
75	17410	229	12279.93	161.52
76	17862	251	12598.74	177.04
77	18296	242	12904.86	170.69
78	18720	293	13203.92	206.66
79	19114	342	13481.82	241.23
80	19498	364	13752.67	256.74
81	19867	324	14012.94	228.53
82	20239	342	14275.33	241.23
83	20602	415	14531.36	292.72
84	20963	497	14785.99	350.55
85	11802	575	8324.39	405.57
86	11813	434	8332.15	306.12
87	11899	409	8392.81	288.48
88	12114	421	8544.46	296.95
89	12189	317	8597.36	223.59
90	12336	326	8701.04	229.94
91	12546	313	8849.16	220.77
92	12763	335	9002.22	236.29
93	13055	357	9208.18	251.81
94	13306	382	9385.22	269.44
95	13445	365	9483.26	257.45
96	13668	501	9640.55	353.37
97	13959	565	9845.81	398.52
98	14156	571	9984.76	402.75
99	14292	535	10080.68	377.36
100	14468	553	10204.82	390.05
101	14637	554	10324.03	390.76
102	14904	613	10512.35	432.37
103	15047	582	10613.21	410.51
104	15208	512	10726.77	361.13

Tabela II - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste com aplicação do alargamento de contraste e sem filtros nos três exames completos (continua)

Teste sem alargamento de contraste sem filtros				
Fatia	Nº de pixels brancos		Área de lesões detectada (mm ²)	
	MATLAB ACM	ORACM	MATLAB ACM	ORACM
Exame 10a_siemens_modiCASGMBH_2mm				
105	15332	569	10814.23	401.34
106	15521	628	10947.54	442.95
107	15715	753	11084.38	531.12
108	15838	748	11171.14	527.59
109	15999	834	11284.7	588.25
110	16053	766	11322.78	540.29
111	16133	792	11379.21	558.63
112	16166	669	11402.49	471.87
113	16374	735	11549.2	518.42
114	16561	894	11681.09	630.57
115	16496	888	11635.25	626.34
116	16056	388	11324.9	273.67
117	16175	403	11408.83	284.25
118	16360	412	11539.32	290.6
119	16556	485	11677.57	342.09
120	16732	517	11801.71	364.66
121	16642	371	11738.23	261.68
122	16653	327	11745.99	230.65
123	17074	770	12042.93	543.11
124	17374	980	12254.53	691.23
125	17005	585	11994.26	412.62
126	16996	556	11987.92	392.17
127	16924	476	11937.13	335.74
128	16979	543	11975.93	383
129	17035	606	12015.42	427.43
130	17310	761	12209.39	536.76
131	17528	869	12363.16	612.94
132	17440	679	12301.09	478.92
133	17769	598	12533.14	421.79
134	17748	601	12518.33	423.91
135	17471	509	12322.95	359.02

Tabela II - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste com aplicação do alargamento de contraste e sem filtros nos três exames completos (continua)

Teste sem alargamento de contraste sem filtros				
Fatia	Nº de pixels brancos		Área de lesões detectada (mm ²)	
	MATLAB ACM	ORACM	MATLAB ACM	ORACM
Exame 10a_siemens_modiCASGMBH_2mm				
136	16886	481	11910.33	339.27
137	17049	620	12025.3	437.31
138	16987	590	11981.57	416.15
139	16868	525	11897.63	370.3
140	16865	340	11895.52	239.81
141	16982	436	11978.04	307.53
142	16934	340	11944.19	239.81
143	16909	340	11926.55	239.81
144	16980	336	11976.63	236.99
145	17506	697	12347.64	491.62
146	17641	850	12442.86	599.54
147	17443	692	12303.2	488.09
148	17628	840	12433.69	592.48
149	17705	864	12488	609.41
150	17422	753	12288.39	531.12
151	17388	683	12264.41	481.75
152	17191	579	12125.46	408.39
153	16969	557	11968.87	392.87
154	16910	465	11927.26	327.98
155	16710	377	11786.19	265.91
156	16810	535	11856.72	377.36
157	16885	717	11909.62	505.73
158	16688	631	11770.67	445.07
159	16424	454	11584.46	320.22
160	16515	662	11648.65	466.93
161	16215	523	11437.05	368.89
162	16369	878	11545.67	619.29
163	16723	1212	11795.36	854.87
164	16555	1127	11676.86	794.92
165	16435	981	11592.22	691.94
166	15958	709	11255.78	500.08

Tabela II - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste com aplicação do alargamento de contraste e sem filtros nos três exames completos (continua)

Teste sem alargamento de contraste sem filtros				
Fatia	Nº de pixels brancos		Área de lesões detectada (mm ²)	
	MATLAB ACM	ORACM	MATLAB ACM	ORACM
Exame 10a_siemens_modiCASGMBH_2mm				
167	15766	589	11120.35	415.44
168	15695	588	11070.27	414.74
169	15537	510	10958.83	359.72
170	15298	410	10790.25	289.19
171	15936	1105	11240.26	779.4
172	15992	1139	11279.76	803.38
173	887	917	625.63	646.79
174	625	648	440.84	457.06
175	1405	1444	991	1018.51
176	1264	1309	891.55	923.29
177	1093	1129	770.93	796.33
178	1073	1134	756.83	799.85
179	1073	1141	756.83	804.79
180	1053	1069	742.72	754.01
181	887	914	625.63	644.68
182	2089	2123	1473.45	1497.43
183	1890	1928	1333.09	1359.89
184	1726	1761	1217.41	1242.1
185	1546	1579	1090.45	1113.73
186	1436	1487	1012.86	1048.84
187	1401	1459	988.18	1029.09
188	1375	1434	969.84	1011.45
189	1383	1462	975.48	1031.2
190	1398	1450	986.06	1022.74
191	1286	1352	907.06	953.62
192	1227	1280	865.45	902.83
193	1344	1444	947.97	1018.51
194	2022	2128	1426.19	1500.96
195	2891	2997	2039.13	2113.9
196	910	1022	641.86	720.85
197	881	996	621.4	702.52

Tabela II - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste com aplicação do alargamento de contraste e sem filtros nos três exames completos (continua)

Teste sem alargamento de contraste sem filtros				
Fatia	Nº de pixels brancos		Área de lesões detectada (mm ²)	
	MATLAB ACM	ORACM	MATLAB ACM	ORACM
Exame 10a_siemens_modiCASGMBH_2mm				
198	877	959	618.58	676.42
199	789	862	556.51	608
200	726	800	512.08	564.27
201	685	753	483.16	531.12
202	650	696	458.47	490.91
203	609	662	429.55	466.93
204	571	636	402.75	448.59
205	541	584	381.59	411.92
206	540	561	380.88	395.69
207	527	555	371.71	391.46
208	509	526	359.02	371.01
209	501	532	353.37	375.24
210	1102	1169	777.28	824.54
211	481	509	339.27	359.02
212	463	494	326.57	348.44
213	376	413	265.21	291.3
214	382	417	269.44	294.13
215	349	387	246.16	272.97
216	347	385	244.75	271.55
217	317	388	223.59	273.67
218	283	335	199.61	236.29
219	284	326	200.32	229.94
220	260	306	183.39	215.83
221	208	254	146.71	179.16
222	197	203	138.95	143.18
223	185	195	130.49	137.54
224	160	181	112.85	127.67
225	150	175	105.8	123.43
226	153	161	107.92	113.56
227	115	129	81.11	90.99
228	109	122	76.88	86.05

Tabela II - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste com aplicação do alargamento de contraste e sem filtros nos três exames completos (continua)

Teste sem alargamento de contraste sem filtros				
Fatia	Nº de pixels brancos		Área de lesões detectada (mm ²)	
	MATLAB ACM	ORACM	MATLAB ACM	ORACM
Exame 10a_siemens_modiCASGMBH_2mm				
229	110	116	77.59	81.82
230	110	115	77.59	81.11
231	86	99	60.66	69.83
232	3846	102	2712.73	71.94
233	3664	92	2584.36	64.89
234	3482	97	2455.99	68.42
235	3274	66	2309.28	46.55
Exame 11a_siemens_modiCASGMBH_2mm				
71	7777	17	7416.73	16.21
72	8193	32	7813.45	30.52
73	8608	29	8209.23	27.66
74	9036	49	8617.4	46.73
75	9489	79	9049.42	75.34
76	9919	69	9459.5	65.8
77	10341	67	9861.95	63.9
78	10791	59	10291.1	56.27
79	11257	71	10735.51	67.71
80	11746	82	11201.86	78.2
81	12185	74	11620.52	70.57
82	12623	84	12038.23	80.11
83	13051	103	12446.4	98.23
84	13474	113	12849.81	107.77
85	13920	128	13275.15	122.07
86	14364	147	13698.58	140.19
87	14816	173	14129.64	164.99
88	15481	197	14763.83	187.87
89	15651	222	14925.96	211.72
90	16044	250	15300.75	238.42
91	16458	261	15695.57	248.91
92	16874	253	16092.3	241.28

Tabela II - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste com aplicação do alargamento de contraste e sem filtros nos três exames completos (continua)

Teste sem alargamento de contraste sem filtros				
Fatia	Nº de pixels brancos		Área de lesões detectada (mm ²)	
	MATLAB ACM	ORACM	MATLAB ACM	ORACM
Exame 11a_siemens_modiCASGMBH_2mm				
93	17312	274	16510.01	261.31
94	17992	284	17158.51	270.84
95	18397	265	17544.75	252.72
96	18809	270	17937.66	257.49
97	19195	285	18305.78	271.8
98	19576	279	18669.13	266.08
99	19916	314	18993.38	299.45
100	20264	337	19325.26	321.39
101	20597	345	19642.83	329.02
102	20968	388	19996.64	370.03
103	21310	406	20322.8	387.19
104	21731	524	20724.3	499.73
105	21814	539	20803.45	514.03
106	22104	528	21080.02	503.54
107	22406	510	21368.03	486.37
108	22671	542	21620.75	516.89
109	22962	550	21898.27	524.52
110	23213	541	22137.64	515.94
111	23466	502	22378.92	478.74
112	23700	518	22602.08	494
113	23949	550	22839.55	524.52
114	24201	542	23079.87	516.89
115	24434	529	23302.08	504.49
116	24685	557	23541.45	531.2
117	24934	553	23778.92	527.38
118	25137	603	23972.51	575.07
119	25587	679	24401.66	647.54
120	25716	722	24524.69	688.55
121	25651	712	24462.7	679.02
122	26029	662	24823.19	631.33
123	26169	653	24956.7	622.75

Tabela II - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste com aplicação do alargamento de contraste e sem filtros nos três exames completos (continua)

Teste sem alargamento de contraste sem filtros				
Fatia	Nº de pixels brancos		Área de lesões detectada (mm ²)	
	MATLAB ACM	ORACM	MATLAB ACM	ORACM
Exame 11a_siemens_modiCASGMBH_2mm				
124	26330	646	25110.24	616.07
125	26469	667	25242.81	636.1
126	26608	704	25375.37	671.39
127	26767	690	25527	658.04
128	26890	706	25644.3	673.29
129	27036	779	25783.54	742.91
130	27286	896	26021.96	854.49
131	27442	979	26170.73	933.65
132	27604	1100	26325.23	1049.04
133	27759	1330	26473.05	1268.39
134	27909	1524	26616.1	1453.4
135	27349	1103	26082.04	1051.9
136	27481	1156	26207.92	1102.45
137	27732	1232	26447.3	1174.93
138	27815	1120	26526.45	1068.12
139	27346	644	26079.18	614.17
140	27197	656	25937.08	625.61
141	27171	730	25912.28	696.18
142	27057	888	25803.57	846.86
143	27127	747	25870.32	712.39
144	28146	1038	26842.12	989.91
145	28220	952	26912.69	907.9
146	28365	821	27050.97	782.97
147	28472	889	27153.02	847.82
148	28254	686	26945.11	654.22
149	28346	671	27032.85	639.92
150	28419	677	27102.47	645.64
151	28445	523	27127.27	498.77
152	28830	549	27494.43	523.57
153	29102	499	27753.83	475.88
154	29440	508	28076.17	484.47

Tabela II - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste com aplicação do alargamento de contraste e sem filtros nos três exames completos (continua)

Teste sem alargamento de contraste sem filtros				
Fatia	Nº de pixels brancos		Área de lesões detectada (mm ²)	
	MATLAB ACM	ORACM	MATLAB ACM	ORACM
Exame 11a_siemens_modiCASGMBH_2mm				
155	29536	409	28167.72	390.05
156	29734	484	28356.55	461.58
157	29858	524	28474.81	499.73
158	30019	522	28628.35	497.82
159	15603	554	14880.18	528.34
160	15624	650	14900.21	619.89
161	16319	338	15563.01	322.34
162	15423	726	14708.52	692.37
163	15506	740	14787.67	705.72
164	15684	835	14957.43	796.32
165	15912	685	15174.87	653.27
166	16328	556	15571.59	530.24
167	16017	604	15275	576.02
168	15534	561	14814.38	535.01
169	15277	530	14569.28	505.45
170	15067	315	14369.01	300.41
171	15136	303	14434.81	288.96
172	16158	435	15409.47	414.85
173	15427	409	14712.33	390.05
174	15895	357	15158.65	340.46
175	16032	509	15289.31	485.42
176	16361	691	15603.07	658.99
177	2727	493	2600.67	470.16
178	2582	486	2462.39	463.49
179	1117	495	1065.25	472.07
180	1776	1124	1693.73	1071.93
181	873	742	832.56	707.63
182	917	802	874.52	764.85
183	881	731	840.19	697.14
184	827	647	788.69	617.03
185	958	759	913.62	723.84

Tabela II - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste com aplicação do alargamento de contraste e sem filtros nos três exames completos (continua)

Teste sem alargamento de contraste sem filtros				
Fatia	Nº de pixels brancos		Área de lesões detectada (mm ²)	
	MATLAB ACM	ORACM	MATLAB ACM	ORACM
Exame 11a_siemens_modiCASGMBH_2mm				
186	862	781	822.07	744.82
187	2786	860	2656.94	820.16
188	2756	849	2628.33	809.67
189	877	720	836.37	686.65
190	1089	944	1038.55	900.27
191	1031	885	983.24	844
192	1364	988	1300.81	942.23
193	1263	1201	1204.49	1145.36
194	1543	1092	1471.52	1041.41
195	4770	1502	4549.03	1432.42
196	993	951	947	906.94
197	952	880	907.9	839.23
198	1077	1063	1027.11	1013.76
199	1144	1119	1091	1067.16
200	1499	1355	1429.56	1292.23
201	1437	1422	1370.43	1356.12
202	1861	1852	1774.79	1766.2
203	1811	1760	1727.1	1678.47
204	1764	1756	1682.28	1674.65
205	1778	1451	1695.63	1383.78
206	1743	1702	1662.25	1623.15
207	1449	1444	1381.87	1377.11
208	1186	1181	1131.06	1126.29
209	1750	1696	1668.93	1617.43
210	1522	1469	1451.49	1400.95
211	1665	1650	1587.87	1573.56
212	2218	2206	2115.25	2103.81
213	2812	2799	2681.73	2669.33
214	3274	3269	3122.33	3117.56
215	3645	3631	3476.14	3462.79
216	4045	4024	3857.61	3837.59

Tabela II - Área de lesões detectada pelas técnicas MATLAB ACM e ORACM no teste com aplicação do alargamento de contraste e sem filtros nos três exames completos (conclusão)

Teste sem alargamento de contraste sem filtros				
Fatia	Nº de pixels brancos		Área de lesões detectada (mm ²)	
	MATLAB ACM	ORACM	MATLAB ACM	ORACM
Exame 11a_siemens_modiCASGMBH_2mm				
217	4277	4233	4078.87	4036.9
218	4644	4426	4428.86	4220.96
219	4757	4740	4536.63	4520.42
220	5102	5096	4865.65	4859.92
221	5501	5490	5246.16	5235.67
222	5845	5838	5574.23	5567.55
223	6157	6148	5871.77	5863.19
224	6515	6509	6213.19	6207.47
225	7234	7212	6898.88	6877.9
226	8049	7887	7676.12	7521.63
227	8692	8686	8289.34	8283.62
228	9388	9384	8953.09	8949.28
229	10227	10217	9753.23	9743.69
230	11024	11017	10513.31	10506.63
231	11607	11591	11069.3	11054.04
232	12337	12304	11765.48	11734.01
233	4397	4272	4193.31	4074.1
234	4771	4583	4549.98	4370.69
235	5300	5063	5054.47	4828.45
236	5574	490	5315.78	467.3
237	448	441	427.25	420.57
238	484	470	461.58	448.23
239	561	534	535.01	509.26
240	447	430	426.29	410.08
241	395	383	376.7	365.26
242	405	386	386.24	368.12
243	378	371	360.49	353.81
244	413	374	393.87	356.67
245	363	322	346.18	307.08
246	338	307	322.34	292.78

Fonte: autoria própria.