



**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO CEARÁ -
IFCE
IFCE CAMPUS FORTALEZA**

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE TELECOMUNICAÇÕES

SAULO MACEDO MAIA

**SEGMENTAÇÃO AUTOMÁTICA DE NÓDULOS PULMONARES NÃO SÓLIDOS EM
IMAGENS DE TOMOGRAFIA COMPUTADORIZADA DO TÓRAX**

FORTALEZA

2022

SAULO MACEDO MAIA

**SEGMENTAÇÃO AUTOMÁTICA DE NÓDULOS PULMONARES NÃO SÓLIDOS EM
IMAGENS DE TOMOGRAFIA COMPUTADORIZADA DO TÓRAX**

Dissertação submetida ao corpo docente da Coordenação do Programa de Pós-Graduação em Engenharia de Telecomunicações do Instituto Federal de Educação, Ciência e Tecnologia do Ceará – IFCE – Campus Fortaleza, como requisito necessário para obtenção do grau de MESTRE EM ENGENHARIA DE TELECOMUNICAÇÕES.

Orientador: Prof. Dr. Tarique da Silveira Cavalcante

Co-orientador: Prof. Dr. Auzuir Ripardo de Alexandria

FORTALEZA

2022

Dados Internacionais de Catalogação na Publicação
Instituto Federal do Ceará - IFCE
Sistema de Bibliotecas - SIBI
Ficha catalográfica elaborada pelo SIBI/IFCE, com os dados fornecidos pelo(a) autor(a)

- M217s Maia, Saulo Macêdo.
 SEGMENTAÇÃO AUTOMÁTICA DE NÓDULOS PULMONARES NÃO SÓLIDOS EM IMAGENS DE
 TOMOGRAFIA COMPUTADORIZADA DO TÓRAX / Saulo Macêdo Maia. - 2022.
 85 f. : il.
- Dissertação (Mestrado) - Instituto Federal do Ceará, Mestrado em Engenharia de Telecomunicações,
 Campus Fortaleza, 2022.
 Orientação: Prof. Dr. Tarique da Silveira Cavalcante.
 Coorientação: Prof. Dr. Auzuir Ripardo de Alexandria.
1. Nódulos não sólidos. 2. segmentação 3D de imagens. 3. manipulação de raios. 4. LIDC/IDRI. 5.
 automático. I. Título.

CDD 621.382

SAULO MACEDO MAIA

**SEGMENTAÇÃO AUTOMÁTICA DE NÓDULOS PULMONARES NÃO SÓLIDOS EM
IMAGENS DE TOMOGRAFIA COMPUTADORIZADA DO TÓRAX**

Dissertação submetida ao corpo docente da Coordenação do Programa de Pós-Graduação em Engenharia de Telecomunicações do Instituto Federal de Educação, Ciência e Tecnologia do Ceará – IFCE – Campus Fortaleza, como requisito necessário para obtenção do grau de MESTRE EM ENGENHARIA DE TELECOMUNICAÇÕES, aprovado pela comissão formada pelos professores:

Aprovado em ____/____/____

BANCA EXAMINADORA

Prof. Dr. Tarique da Silveira Cavalcante
(Orientador)

Programa de Pós-Graduação em Engenharia de
Telecomunicações, Campus Fortaleza (IFCE)

Prof. Dr. Auzuir Ripardo de Alexandria
(Co-orientador)

Programa de Pós-Graduação em Engenharia de
Telecomunicações, Campus Fortaleza (IFCE)

Prof. Dr. Paulo César Cortez
Programa de Pós-Graduação em Engenharia de
Teleinformática, Universidade Federal do Ceará
(UFC)

Prof. Dr. Regis Cristiano Pinheiro Marques
Programa de Pós-Graduação em Engenharia de
Telecomunicações, Campus Fortaleza (IFCE)

Profa. Dra. Ingrid Correia Nogueira
Mestrado Profissional em Tecnologia
Minimamente Invasiva e Simulação na Área da
Saúde, Centro Universitário Christus
(UniChristus)

À Deus, meus pais Maia e Norma, e meus irmãos Matheus e Marcus...

AGRADECIMENTOS

À Deus agradeço, pela dádiva da vida, por me permitir realizar tantos sonhos nesta existência e por trilhar meu caminho e entregar meu destino nas mãos de pessoas tão especiais, meus pais.

Gostaria de realçar a insubstituível importância da minha família em minha vida, especialmente à minha mãe Norma Macêdo Maia e ao meu pai José Silva Maia que me incentivaram e forneceram todos os meios possíveis para estudar, sempre com muito amor e dedicação ao longo desta jornada. Vocês são meus exemplos de vida e serei infinitamente grato.

Aos meus irmãos Matheus Macêdo Maia e Marcus Macêdo Maia, meus melhores amigos. Nosso amor é o elo que nos une e nos unirá para sempre.

À minha tia Linda Síria Rocha Caetano, pelo apoio e confiança. Com a senhora aprendi que a vida é feita de você e não para você. Me esforcei para dar sequência ao seu legado.

À minha, em breve, esposa Fátima Daiana Dias Barroso pelo apoio, pela dedicação, pela paciência, pela persistência, pelo amor e por tudo.

Ao professor Tarique da Silveira Cavalcante pela orientação acadêmica e de vida, amizade, confiança, por ser para mim inspiração pessoal e profissional e por todas as oportunidades e condições que me proporcionou para a realização deste trabalho.

Ao professor Auzuir Ripardo de Alexandria pela confiança e oportunidade depositada desde a graduação e por me ensinar diariamente a ser mais humano.

Aos companheiros de projeto de pesquisa pela paciência, ajuda, contribuição e ensinamentos que me foram passados durante essa jornada, em especial agradeço aos amigos Alyson Bezerra Nogueira Ribeiro, Lyndainês Araújo, Pedro Elias Ribeiro dos Santos, Renê Ripardo Calixto, Thomaz Maia de Almeida e Valberto Enoc Rodrigues da Silva Filho.

Ao Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE), em especial ao Polo de Inovação do IFCE.

“If you are in trouble, double.”

(Autor desconhecido.)

RESUMO

O câncer é um dos maiores problemas de saúde e umas das principais causas de morte em todo o mundo. A mortalidade por câncer pode ser reduzida se os casos forem detectados e tratados precocemente. Para isso, assim como em diversas aplicações de análise de imagens médicas, o processo de segmentação destas imagens é uma tarefa fundamental, principalmente quando se trata de sistemas de auxílio ao diagnóstico de doenças como o câncer de pulmão. Porém a segmentação manual e volumétrica de um nódulo pulmonar, é um procedimento que consome bastante tempo quer sejam para nódulos sólidos ou para nódulos não sólidos. A detecção e tratamento precoce de nódulos não sólidos se torna mais crítica devido aos mesmos, apesar de apresentarem uma menor taxa de ocorrência, apresentarem altas taxas de malignidade. A detecção e, por consequência, a segmentação de nódulos não sólidos, são processos extremamente desafiadores, pelo fato desse tipo de lesão possuir densidade similar ao parênquima pulmonar e bordas com atenuação ligeiramente turva e pouco definidas. Deste modo, diferentes abordagens são utilizadas para promover a segmentação de nódulos não sólidos a partir de imagens de Tomografia Computadorizada (TC) do tórax, entretanto a maioria delas de forma semi-automática. Neste sentido, esta dissertação propõe uma abordagem para segmentação automática de nódulos não sólidos em imagens de TC do tórax, empregando técnicas de manipulação de raios e ponderação de energia baseada na média das intensidades, além de morfologia matemática clássica para refinar as bordas da lesão. Esta abordagem é composta por uma sequência de pré-processamento seguida da geração de dois grupos de raios e aplicação de Média de Densidades Bidirecional Iterativa (MDBI) baseada na ponderação de energia para delimitação das bordas da lesão. Na sequência, ainda compõem o método proposto um crescimento de região 3D com limiares iterativos de acordo com as intensidades da lesão e do parênquima, remoção de parede pulmonar e de vasos anexos ao nódulo utilizando análise de componentes conectados e transformada da distância. Finalmente, as bordas do nódulo são reconstruídas e refinadas através de operações morfológicas. Para validar a abordagem, um conjunto específico de nódulos baseados no banco de imagens de LIDC/IDRI foi determinado e três experimentos foram elaborados para comparar tanto a performance do método de segmentação proposto com as segmentações de referências dos radiologistas especialistas, como o nível de concordância entre os próprios médicos. Os resultados comprovam que há uma significativa variação de concordância entre os médicos quanto às marcações de uma lesão não sólida, fundamentando que é um processo extremamente subjetivo e complexo. Além disso, a técnica obteve uma acurácia geral de segmentação de 88,98% e um tempo médio de segmentação de 0,85 segundos. Quanto à qualidade da segmentação, resultados 2D e 3D revelam que há uma sobresegmentação causada pelo método mas que a mesma apresenta características de densidade semelhante às marcações de nódulo realizadas pelos médicos. Neste contexto, conclui-se que a segmentação proposta, segundo as métricas utilizadas, apresenta resultados adequados para auxílio ao diagnóstico médico e implantação na prática clínica, bem como o tempo de processamento reduzido,

sendo compatível aos métodos encontrados na literatura quanto às medidas de qualidade da segmentação.

Palavras-chave: nódulos não sólidos, segmentação 3D de imagens, manipulação de raios, LIDC/IDRI, automático.

(Algumas figuras podem aparecer coloridas apenas na versão digital)

ABSTRACT

Cancer is one of the biggest health problems and one of the leading causes of death worldwide. Cancer mortality can be reduced if cases are detected and treated early. For this, as in several medical image analysis applications, the process of segmenting these images is a fundamental task, especially when it comes to systems to aid the diagnosis of diseases such as lung cancer. However, manual and volumetric segmentation of a pulmonary nodule is a time-consuming procedure whether for solid or subsolid nodules. The early detection and treatment of subsolid nodules becomes more critical because, despite having a lower rate of occurrence, they have high rates of malignancy. The detection and, consequently, the segmentation of subsolid nodules, are extremely challenging processes, due to the fact that this type of lesion has a density similar to the lung parenchyma and edges with slightly blurred and poorly defined attenuation. Thus, different approaches are used to promote the segmentation of subsolid nodules from Computed Tomography (CT) images of the chest, however most of them are semi-automatic. In this sense, this dissertation proposes an approach for automatic segmentation of subsolid nodules on CT images of the chest, employing radius manipulation techniques and energy weighting based on the average of intensities, in addition to classical mathematical morphology to refine the edges of the lesion. This approach consists of a pre-processing sequence followed by the generation of two groups of radius and application of Bidirectional Density Average Iterative (BDAI) based on energy weighting to delimit the lesion edges. In the sequence, the proposed method still comprises a 3D region growth with iterative thresholds according to the intensities of the lesion and parenchyma, removal of the lung wall and vessels attached to the nodule using analysis of connected components and distance transform. Finally, the edges of the nodule are reconstructed and refined through morphological operations. To validate the approach, a specific set of nodules based on the LIDC/IDRI image dataset was determined and three experiments were designed to compare both the performance of the proposed segmentation method with the segmentations of specialist radiologists references, and the level of agreement among the observer themselves. The results prove that there is a significant variation in agreement between physicians regarding the markings of a subsolid lesion, substantiating that it is an extremely subjective and complex process. In addition, the technique obtained an overall segmentation accuracy of 88.98% and an average segmentation time of 0.85 seconds. As for the quality of segmentation, 2D and 3D results reveal that there is an oversegmentation caused by the method, but that it has density characteristics similar to the nodule markings performed by physicians. In this context, it is concluded that the proposed segmentation, according to the metrics used, it presents adequate results to aid in medical diagnosis and implementation in clinical practice, as well as reduced processing time, being compatible with the methods found in the literature regarding segmentation quality measures.

Keywords: subsolid nodule. 3D image segmentation. radius manipulation. LIDC/IDRI. automatic.

(Some figures may appear in color only in the digital version)

LISTA DE ILUSTRAÇÕES

Figura 1	– Número de novos casos e mortalidade (em milhares) para o ano de 2020 e estimativa para os anos de 2025 e 2030 no Brasil para os tipos de câncer de traquéia, brônquios e pulmão.	19
Figura 2	– Distribuição proporcional dos dez tipos de câncer mais incidentes estimados para 2020 e mais letais estimados para 2019, por sexo no Brasil	21
Figura 3	– Destaques de um exame de tomografia computadorizada, representando os três tipos de nódulos: a) sólido b) parcialmente sólido ou misto c) não sólido	23
Figura 4	– Imagens de seções do pulmão. (a) Plano de corte em relação ao corpo humano; (b) seção sagital; (c) seção axial; e (d) seção coronal	24
Figura 5	– Representação do processo de aquisição de tomografia computadorizada. a) Ilustração dos movimentos da máquina e sentido de propagação dos raios-x, durante um procedimento típico de tomografia computadorizada. b) <i>Slices</i> de imagens empilhadas para formação da representação 3D	25
Figura 6	– Escala em unidades Hounsfield de estruturas do corpo humano	26
Figura 7	– Representação de uma imagem em diferentes espaço de cores. Representação no espaço de cor (a) binário; (b) tom de cinza; (c) RGB	27
Figura 8	– Efeitos da amostragem na aparência e qualidade de uma imagem. (a) $225 \times 250 \text{ pixels}$; (b) $112 \times 125 \text{ pixels}$; (c) $56 \times 62 \text{ pixels}$; (d) $28 \times 31 \text{ pixels}$. Todas as quatro imagens têm 256 tons de cinza e 8 <i>bits</i> por <i>pixel</i>	28
Figura 9	– Sistema de visão computacional típico	29
Figura 10	– Imagem "rotulada": (a) Imagem original compsta por regiões conjuntas de <i>pixels</i> . (b) Imagem final após o processamento de rotulação. As cores são utilizadas para auxiliar na visualização das regiões	30
Figura 11	– Principais atributos de região, ou seja, dos objetos independentes presentes na imagem	31
Figura 12	– Processo de limiarização. (a) Imagem original; (b) segmentação por limiarização; (c) <i>threshold</i> muito baixo e (d) <i>threshold</i> muito alto	32
Figura 13	– Exemplos de elementos estruturantes, onde cada quadrado indica um membro do ES. Os pontos indicam os centros dos ESs	34
Figura 14	– Erosão de um conjunto X por um elemento estruturante em disco B	35
Figura 15	– Dilatação de um conjunto X por um elemento estruturante em disco B	36
Figura 16	– Abertura de um conjunto X por um elemento estruturante em disco B	37
Figura 17	– Fechamento de um conjunto X por um elemento estruturante em disco B	37
Figura 18	– Representação da operação de <i>convex hull</i> em uma região côncava. (a) caracteres côncavos; (b) o menor conjunto convexo contendo cada caracater definindo o <i>convex hull</i>	38

Figura 19 – Extrair componentes conectados. (a) Elemento estruturante; (b) arranjo matricial contendo um conjunto com um componente conectado; (c) arranjo inicial; (d) a (g) vários passos na iteração da equação 2.8	38
Figura 20 – Diferentes tipos de nódulos pulmonares com o contorno da segmentação manual (vermelho) fornecido pelo banco de dados LIDC/IDRI. a) Nódulo sólido b) nódulo não sólido c) nódulo não sólido com o núcleo sólido d) nódulo sólido anexo à parede do pulmão e) nódulo sólido com vasos adjacentes f) nódulo não sólido com vasos adjacentes	40
Figura 21 – Remoção de vasos pulmonares e separação das componentes sólida e não-sólida presente em um nódulo semissólido misto	41
Figura 22 – Resultados do método de segmentação representado pelo contorno vermelho, e os contornos verde, amarelo, azul claro e azul escuro sendo as segmentações de referência	42
Figura 23 – Resultados do método de segmentação representado pelo contorno vermelho, e os contorno amarelo sendo a segmentação de referência realizada por um radiologista	43
Figura 24 – Etapas do processo de segmentação para o eixo axial de um nódulo não sólido, caso 298-0. (a) Representação das quatro marcações originais dos radiologistas. (b) <i>Slice</i> 2D representando o centróide do nódulo. (c) Disposição de todos os raios criados sobre o nódulo. (d) Representação dos pontos de possíveis bordas que indicam os limites da lesão. (e) Seleção e armazenamento das coordenadas referentes as três maiores combinações de raios. (f) Região inicial do nódulo R_0 calculada a partir de um limiar baseado na operação de crescimento de regiões. (g) <i>Convex hull</i> do negativo da região R_0 . (h) R_{final} resultante da aplicação de operações morfológicas	46
Figura 25 – Pontos no sistema de coordenadas polares com o polo O e o eixo L	47
Figura 26 – Distribuição dos raios sobre (a) nódulo sintético e (b) nódulo real	47
Figura 27 – Organização de uma dataframe e representação de suas partes	48
Figura 28 – Representação numérica da aplicação e cálculo do critério de parada e suas particularidades	49
Figura 29 – Representação sintética da aplicação da ponderação de energia baseada na média das densidades. (a) raio original de referência e (b) raio resultante pós ponderação de energia	50
Figura 30 – Modelo de borda com perfil de intensidade no formato de rampa	51
Figura 31 – Determinação do campo de busca. (a) definição das regiões R_1 e R_2 e (b) cálculo da melhor combinação baseado na distância euclidiana entre as extremidades dos raios dentro do campo de busca e a extremidade do raio de referência	52

Figura 32 – Seleção do raio resultante pós sucessivos cálculos de distância entre os raios em análise. (a) demonstração do raio resultante e (b) amostra da lista com as informações das combinações de raios ordenadas pelo comprimento	53
Figura 33 – Representação sintética do volume de interesse <i>B</i> composto por região de nódulo e região não-nódulo assim como outras estruturas presentes no parênquima pulmonar	54
Figura 34 – Refino da região do nódulo. (a) nódulo original com as respectivas marcações dos 4 médicos especialistas. (b) segmentação resultante da etapa de remoção da parede pulmonar mas ainda com regiões de pleura. (c) segmentação final após etapa de remoção de vasos anexos e reconstrução do nódulo. Caso 75-3	56
Figura 35 – Infográfico experimento 1	59
Figura 36 – Nódulo original, máscara de segmentação resultante do método proposto (contorno amarelo), máscara de referência <i>consensus</i> (contorno roxo) e máscaras individuais dos médicos 1 (contorno vermelho), 2 (contorno verde), 3 (contorno verde) e 4 (contorno laranja), para resultados de segmentação do experimento 1. a) Caso 48-2. b) Caso 179-0. c) Caso 394-5	60
Figura 37 – Nódulo original, máscara de segmentação resultante do método proposto (contorno amarelo), máscara de referência união (contorno rosa) e máscaras individuais dos médicos 1 (contorno vermelho), 2 (contorno verde), 3 (contorno verde) e 4 (contorno laranja), para resultados de segmentação do experimento 1. a) Caso 223-0. b) Caso 777-3. c) Caso 587-0	61
Figura 38 – Sequência de 5 <i>slices</i> para o a) nódulo original, b) máscara de referência <i>consensus</i> e c) máscara de segmentação resultante do método proposto. Caso 402-4	62
Figura 39 – Sequência de 5 <i>slices</i> para o a) nódulo original, b) máscara de referência união e c) máscara de segmentação resultante do método proposto. Caso 339-0	62
Figura 40 – Infográfico experimento 3	63
Figura 41 – Nódulo original, máscara de segmentação resultante do método proposto (contorno amarelo) e máscaras de segmentação dos médicos 1 (contorno vermelho), 2 (contorno verde), 3 (contorno verde) e 4 (contorno laranja), para resultados de segmentação do experimento 3. a) Caso 223-0. b) Caso 298-0. c) Caso 686-4	63
Figura 42 – <i>Slices</i> representando caso que justifica a elaboração do critério 2, onde o método obtém como resultado de segmentação componentes únicos de volume irrelevantes ou múltiplos componentes dispersos também de volume insignificantes. A primeira linha (itens a,b e c) revela as marcações do <i>consensus</i> e a segunda linha (itens d,e e f) as marcações do método de segmentação, ambas para uma mesma sequência de <i>slices</i> do caso 394-3	65

Figura 43 – Três <i>slices</i> representando um caso que justifica a elaboração do critério 3, onde o método obtém como resultado de segmentação componentes fora da região do nódulo. A primeira linha (itens a,b e c) revela as marcações do <i>consensus</i> e a segunda linha (itens d,e e f) as marcações do método de segmentação, ambas para uma mesma sequência de <i>slices</i> do caso 539-0 . . .	66
Figura 44 – Representação de casos onde há alta variância quanto as marcações dos médicos especialistas para um mesmo nódulo. Casos (a) 08-0, (b) 388-1, (c) 777-2, (d) 994-3	69
Figura 45 – Representação de casos que comprovam uma ou mais marcações desconforme com as demais. Casos (a) 128-2, (b) 240-0, (c) 298-0, (d) 539-0	70
Figura 46 – Representações 2D da comparação por <i>slices</i> entre as segmentações da a) referência <i>consensus</i> e do b) método de segmentação proposto, ambas para uma mesma sequência de <i>slices</i> do caso 131-1	71
Figura 47 – Representações 3D da comparação dos volumes segmentados pelo (a) método segmentação proposto e (b) referência <i>consensus</i> . Caso 131-1	71
Figura 48 – Representações 2D da comparação por <i>slices</i> entre as segmentações da a) referência <i>consensus</i> e do b) método de segmentação proposto, ambas para uma mesma sequência de <i>slices</i> do caso 498-1	72
Figura 49 – Representações 3D da comparação dos volumes segmentados pelo (a) método segmentação proposto e (b) referência <i>consensus</i> . Caso 498-1	72
Figura 50 – Nódulo original, máscara de segmentação resultante do método (contorno amarelo) e máscaras de segmentação dos médicos 1 (contorno vermelho), 2 (contorno verde), 3 (contorno verde) e 4 (contorno laranja), para resultados de segmentação do experimento 3. a) Caso 179-0. b) Caso 240-0. c) Caso 288-1. d) Caso 480-0	73
Figura 51 – Distribuição dos valores para a métrica de <i>Jaccard Index</i> resultantes do experimento 3 que tem o objetivo de determinar a reprodutibilidade do método proposto de segmentação	73

LISTA DE TABELAS

Tabela 1	– Número de novos casos e mortalidade (em milhões) para o ano de 2020 e estimativa para o ano de 2025 no mundo para os tipos de câncer geral (com exceção do câncer de pele não-melanoma) e para câncer de traquéia, brônquios e pulmão.	18
Tabela 2	– Informações dos valores máximo, mínimo e médio para o <i>slice thickness</i> , diâmetro, área e volume para os nódulos do conjunto de dados.	57
Tabela 3	– Resultados para as métricas de <i>Jaccard Index</i> e <i>Dice Coefficient</i> da comparação entre as máscaras binárias resultantes do método proposto de segmentação e as máscaras binárias de referências <i>consensus</i> e união.	67
Tabela 4	– Resultados para as métricas de <i>Jaccard Index</i> e <i>Dice Coefficient</i> da comparação entre as máscaras binárias resultantes do método proposto de segmentação e as máscaras binárias resultantes da segmentação dos médicos.	67
Tabela 5	– Resultados para as métricas de <i>Jaccard Index</i> e <i>Dice Coefficient</i> da comparação para as máscaras binárias resultantes de segmentação entre os médicos.	68
Tabela 6	– Resultados para as métricas de <i>Jaccard Index</i> e <i>Dice Coefficient</i> da comparação entre as máscaras de segmentação do método e as referências <i>consensus</i> e união somente para <i>slices</i> com marcação.	69

LISTA DE ABREVIATURAS E SIGLAS

CAD	Computer Aided Diagnostic
CR	Crescimento de Região
DICOM	Digital Imaging and Communicantions in Medicine
DSC	Dice Similarity Coefficient
GGN	Ground-Glass Nodule
GGO	Ground-Glass Opacity
IARC	International Agency for Research on Cancer
IDRI	Image Database Resource Initiative
I-ELCAP	International Early Cancer Action Project
INCA	Instituto Nacional de Câncer
JI	Jaccard Index
LIDC	Lung Image Database Consortium
MDBI	Media de Densidades Bidirecional Iterativa
PDI	Processamento Digital de Imagens
TC	Tomografia Computadorizada
UH	Unidade Hounsfield
VC	Visão Computacional

SUMÁRIO

1	INTRODUÇÃO	18
1.1	Objetivos	20
1.1.1	Objetivos Específicos	20
2	FUNDAMENTAÇÃO TEÓRICA E ESTADO DA ARTE	21
2.1	Câncer de Pulmão	21
2.2	Nódulos Pulmonares	22
2.3	Tomografia Computadorizada	23
2.4	Processamento Digital de Imagens	25
2.5	Visão Computacional	28
2.5.1	Segmentação	31
2.5.1.1	Limiarização	31
2.5.1.2	Crescimento de Regiões	33
2.5.2	Morfologia Matemática ou Processamento Morfológico de Imagens . . .	33
2.5.2.1	Erosão e Dilatação	34
2.5.2.2	Abertura e Fechamento	35
2.5.2.3	Análise de Componentes Conectados	36
2.6	Segmentação de Nódulos Pulmonares	38
3	METODOLOGIA	45
3.1	Segmentação Automática de Nódulos Não Sólidos	45
3.1.1	Conjunto Inicial de Raios	45
3.1.2	Conjunto de Raios Derivados	48
3.1.3	Campo de Busca Suplementar	50
3.1.4	Região de Interesse e Análise de Histograma	52
3.1.5	Crescimento de Região	54
3.1.6	Remoção de Parede Pulmonar	55
3.1.7	Remoção de Vasos Anexos e Reconstrução do Nódulo	55
3.2	Dados	56
3.3	Experimentos	57
3.3.1	Experimento 1	58
3.3.2	Experimento 2	59
3.3.3	Experimento 3	60
4	RESULTADOS E DISCUSSÕES	64
4.1	Desempenho do Método de Segmentação	64
4.2	Qualidade da Segmentação	66

4.2.1	Experimento 1	67
4.2.2	Experimento 2	68
4.2.3	Experimento 3	70
5	CONCLUSÃO, CONTRIBUIÇÕES E TRABALHOS FUTUROS	74
	REFERÊNCIAS	76

1 INTRODUÇÃO

O câncer é um dos maiores problemas de saúde e umas das principais causas de morte em todo o mundo, e devido a isso merece que sejam realizados progressos de forma mais urgente contra essa doença. A incidência de câncer aumenta dramaticamente com o avanço da idade, assim como também de outros fatores como o uso de tabaco, álcool, dieta pouco saudável, sedentarismo e poluição do ar. Conforme a *International Agency for Research on Cancer* (IARC, 2022) foram computados no ano de 2020, 18,1 milhões de novos casos de câncer, com exceção do câncer de pele não-melanoma, sendo 2,21 milhões destes (12,2%) somente de câncer de traquéia, brônquios e pulmão para ambos os sexos. A estimativa para o ano de 2025 é de 20,5 milhões de novos casos, sendo 2,54 milhões de câncer de traquéia, brônquios e pulmão. Dessa forma, calcula-se um aumento de aproximadamente 15% em relação ao ano de 2020.

Acredita-se que, de acordo com as tendências, este aumento de 15% também revele o crescimento no número de mortes para o ano de 2025 (11,3 milhões para todos os tipos de câncer com exceção do de pele não-melanoma e 2,07 milhões para traquéia, brônquios e pulmão) comparado ao ano de 2020 (9,89 milhões para todos os tipos de câncer com exceção do de pele não-melanoma e 1,80 milhões para traquéia, brônquios e pulmão). A Tabela 1 expõe com detalhes os números de novos casos e mortalidade no mundo para várias categorias e cenários.

Tabela 1 – Número de novos casos e mortalidade (em milhões) para o ano de 2020 e estimativa para o ano de 2025 no mundo para os tipos de câncer geral (com exceção do câncer de pele não-melanoma) e para câncer de traquéia, brônquios e pulmão.


Tipos de Câncer	Novos casos				Mortalidade			
	Homem		Mulher		Homem		Mulher	
	2020	2025	2020	2025	2020	2025	2020	2025
Geral	9,34	10,7	8,75	9,78	5,49	6,31	4,40	5,00
Pulmão	1,44	1,66	0,77	0,88	1,19	1,38	0,607	0,69

Fonte: (IARC, 2022)

No Brasil, a estimativa é que o aumento percentual seja maior comparado ao resto do mundo. Considerando somente câncer de traquéia, brônquios e pulmão, em 2025 a expectativa é que sejam 48 mil novos casos de encontro a 40,4 mil no ano de 2020, podendo chegar a 56,2 mil novos casos no ano de 2030. No tocante à mortalidade, há a expectativa de termos 41,9 mil mortes, ou seja, um aumento de 19% comparado as 35,2 mil mortes de 2020, podendo chegar a 49,3 mil mortes em 2030 (IARC, 2022). A Figura 1 expõe com detalhes os números de novos casos e mortalidade no Brasil, para câncer de traquéia, brônquios e pulmão para ambos os sexos.

A mortalidade por câncer pode ser reduzida se os casos forem detectados e tratados precocemente. Para isso, de acordo com a Organização Pan-Americana de Saúde (OPAS, 2022), existem dois componentes para a detecção precoce: o rastreamento e o tratamento precoce. Em geral, um programa de rastreamento é uma intervenção de saúde pública muito mais complexa em comparação ao diagnóstico precoce, e tem como objetivo identificar indivíduos com anormalidades sugestivas de um câncer específico ou pré-câncer que não tenha desenvolvido nenhum sintoma e encaminhá-lo prontamente para diagnóstico e tratamento. Já o diagnóstico precoce é relevante em todos os contextos e na maioria dos tipos de câncer. Quando identificado precocemente, o câncer pode responder melhor a um tratamento eficaz e isso resulta em uma

Figura 1 – Número de novos casos e mortalidade (em milhares) para o ano de 2020 e estimativa para os anos de 2025 e 2030 no Brasil para os tipos de câncer de traquéia, brônquios e pulmão.



Fonte: Elaborada pelo autor adaptada de IARC (2022)

maior probabilidade de sobrevivência, menor taxa de mortalidade e um tratamento menos dispendioso.

Técnicas computacionais avançadas e de inteligência artificial têm sido aliadas à medicina no que diz respeito ao auxílio ao diagnóstico médico. O processo de detecção manual é realizado por um humano, é um processo desafiador que consome muito tempo da prática clínica e muitas vezes passível de erros. Para superar esses desafios e com o objetivo de se ter uma detecção precoce e por consequência um tratamento precoce e um aumento na taxa de sobrevivência do indivíduo, vários trabalhos têm aplicado esses tipos de técnicas, na tarefa de se realizar a detecção precoce de forma automática. Diversos desses trabalhos dedicados à tarefa de detecção precoce de câncer em geral como mama, cabeça e pescoço, cólon, pele e outros (ANGAYARKANNI, 2022; KOH et al., 2022; MUSALLAM; SHERIF; HUSSEIN, 2022; MANZOOR et al., 2022; MAHMOOD et al., 2021), assim como alguns mais especificamente aplicados à detecção de nódulos pulmonares (YUAN et al., 2021; MANICKAVASAGAM; SELVAN; SELVAN, 2022; HOLBROOK et al., 2021; SUN et al., 2021; CHIU; TSAI; SU, 2021).

O diagnóstico tardio, ou seja, em um estágio avançado da doença, faz com que o tratamento curativo de retirada do tumor, em muitas vezes, não seja mais uma opção. Neste sentido, é importante para os sistemas de saúde pública, o uso de meios que proporcionem diagnósticos mais rápidos e precisos. Para isso, exames de imagem como radiografia e tomografia computadorizada (TC), são bastantes utilizados para a detecção e caracterização da doença. Tratando especificamente da TC, essa modalidade de exame de imagem apresenta várias vantagens como boa resolução de imagens, permitindo diagnósticos mais precisos, rapidez na realização, custo relativamente menor comparado a outras categorias de exames de imagem, além de ser uma técnica não invasiva (WOOD, 2014). O rastreamento do câncer de pulmão com exames de TC de baixa dose, podem levar ao diagnóstico precoce e à cura de milhares de pacientes a cada ano. No Brasil, existem 5893 equipamentos de tomografia disponíveis e no ano de 2020, 160.806 exames de TC foram realizados (CNESNET, 2022).

A TC se destaca pela diversidade de doenças que permite diagnosticar, bem como os diferentes tipos de tumores existentes (SILVA FILHO, 2018). Para o câncer de pulmão, a tomografia computadorizada é o exame de maior importância na detecção de nódulos pulmonares. A TC cria detalhadas imagens 3D por combinação das informações de várias imagens 2D,

permitindo que seja possível determinar o tamanho e a localização do tumor no pulmão. Para que se consiga calcular o volume da lesão, se faz necessária segmentá-la tridimensionalmente, para que sejam fornecidos meios para a extração de informações relevantes à região segmentada, reconstrução visual ou mesmo para a simulação e planejamento cirúrgico.

O procedimento de segmentação é, sem dúvidas, uma das tarefas mais importantes e difíceis, seja ela executada de forma manual, semi-automática ou automática. A segmentação manual de uma estrutura volumétrica, como nódulos pulmonares, é um processo monótono e demorado que leva em média 5 a 10 minutos. Dessa forma, a segmentação automática de nódulos em exames de TC, se apresenta como uma técnica que possibilita a otimização de atividades nas rotinas clínicas, favorecendo ainda mais a detecção e tratamento precoce. Dentre os tipos de nódulos pulmonares, nódulos sólidos com bordas bem definidas são mais fáceis de serem segmentados e o grande desafio passa a ser a delimitação dos nódulos não sólidos, já que estes possuem densidade semelhante ao parênquima pulmonar que o contorna.

Neste contexto, é proposto nesta dissertação o desenvolvimento de um método para segmentação automática 3D de nódulos pulmonares não sólidos a partir de imagens de tomografia computadorizada do tórax. Este método visa auxiliar o diagnóstico médico, permitindo que o especialista consiga de forma rápida e confiável encaminhar o paciente ao correto tratamento através do processo de segmentação da lesão, contribuindo com os fatores determinantes detecção precoce e taxa de crescimento da lesão.

1.1 Objetivos

O principal objetivo desta dissertação é propor uma técnica de segmentação automática 3D de nódulos pulmonares não sólidos a partir de imagens de tomografia computadorizada do tórax.

1.1.1 Objetivos Específicos

Os objetivos específicos que devem ser alcançados neste trabalho são:

- implementar e avaliar uma estratégia baseada na geração de raios e manipulação de coordenadas polares para se definir o maior diâmetro de um nódulo não sólido;
- elaborar e avaliar um critério para delimitação das bordas de um nódulo não sólido;
- selecionar e validar a geração de banco de imagens específico a partir do LIDC-IDRI;
- validar as segmentações de nódulos não sólidos realizadas pelo algoritmo proposto com padrão ouro obtido.

2 FUNDAMENTAÇÃO TEÓRICA E ESTADO DA ARTE

2.1 Câncer de Pulmão

O câncer é o principal problema de saúde pública no mundo e a segunda causa de mortes mais comum (WILD; WEIDERPASS; STEWART, 2020). De acordo com o *World Cancer Report* da *International Agency for Research on Cancer* (IARC), estima-se que no ano de 2020, 18,1 milhões de mortes foram causadas por algum tipo de câncer no mundo. As previsões são que os números de casos excedam os 27 milhões por ano em 2040, estimativa essa 24% maior em relação aos 20,5 milhões de novos casos no ano de 2025. De todos os tipos de câncer, o câncer de pulmão registrou somente em 2020, 2,21 milhões de novos casos e 1,8 milhões de novas mortes, sendo responsável por 18% de todas as mortes por câncer (BRAY et al., 2018), ocupando assim a primeira posição de câncer mais comum entre os homens e a terceira posição entre as mulheres.

No Brasil, o câncer é a segunda causa mais comum de mortes prematuras ficando atrás somente das doenças cardiovasculares (INCA, 2019). A estimativa para cada ano do triênio 2020-2022 indica que haverão 625 mil novos casos de câncer, sendo 40,4 mil desses unicamente de câncer de pulmão, segundo o IARC (2022). Somente no Brasil no ano de 2020 ocorreram 35,2 mil óbitos causados pelo câncer de pulmão, valores que correspondem a um risco estimado de aproximadamente 16 óbitos a cada 100 mil homens e de aproximadamente 12 óbitos a cada 100 mil mulheres. Os valores estimados dos números de novos casos para o ano de 2020 e dos números de óbitos para o ano de 2019, por sexo no Brasil de acordo com o último estudo do INCA, são mostrados na Figura 2.

Figura 2 – Distribuição proporcional dos dez tipos de câncer mais incidentes estimados para 2020 e mais letais estimados para 2019, por sexo no Brasil



Fonte: Elaborada pelo autor adaptada de INCA (2019)

As elevadas taxas de incidência e de mortalidade por câncer, devem-se em parte pelo envelhecimento e crescimento populacional além de fatores associados ao desenvolvimento socioeconômico, hábitos e atitudes vinculadas à urbanização como sedentarismo, alimentação inadequada, entre outros. Quanto ao câncer de pulmão, a estratégia mais efetiva na redução das taxas de mortalidade e incidência de novos casos é a diminuição do principal fator de risco, o tabaco (INCA, 2019). Os riscos aumentam consideravelmente e proporcionalmente ao tempo de exposição passiva e a quantidade de consumo do produto. Segundo o INCA, 85% dos casos diagnosticados estão associados ao consumo de derivados do tabaco. Outros fatores de risco são a presença de doença pulmonar preexistente, exposição ocupacional a agentes químicos ou físicos e altas doses de suplementos de betacaroteno em fumantes e ex-fumantes (SOCIETY, 2020).

Além dos fatores citados anteriormente, essas altas taxas podem ser atribuídas ao fato de que, atualmente, apenas 15% de todos os cânceres de pulmão são diagnosticados precocemente (SOCIETY, 2020). A grande importância desse fato é que regularmente a maioria dos sintomas não acontecem antes que o câncer esteja em estado avançado, diminuindo consideravelmente a sobrevida e limitando bastante as chances de cura. Caso um câncer de pulmão seja detectado precocemente ainda em um estágio inicial, as opções de tratamento disponíveis aumentam e a taxa de sobrevida relativa aos próximos 5 anos aumenta de 17% para 54% (SOCIETY, 2020). Dessa forma, a detecção precoce do câncer de pulmão é uma das principais estratégias para reduzir a mortalidade desse tipo de câncer.

2.2 Nódulos Pulmonares

Nódulos pulmonares são definidos como uma opacidade arredondada ou irregular, bem ou mal definida, medindo até 3 *cm* de diâmetro (HANSELL et al., 2008). A ocorrência de nódulos não está associada somente ao diagnóstico de câncer de pulmão. Outras doenças pulmonares como, por exemplo, a silicose crônica é visualmente caracterizada por pequenos nódulos sólidos bem definidos, os chamados micronódulos. A detecção de nódulos pulmonares, a clara diferenciação dos micronódulos e a correta avaliação do seu nível de malignidade, são indispensáveis para identificar o câncer de pulmão ainda em estágio inicial.


Os nódulos pulmonares podem ser diferenciados, baseado em suas características e aparência no exame de Tomografia Computadorizada (TC), em sólidos e semissólidos. Por definição, os nódulos sólidos, que são a grande maioria das ocorrências, são descritos por uma região com intensidade homogênea e de elevada atenuação, que se destaca perante a arquitetura do parênquima subjacente e até mesmo aos vasos, o que os tornam mais destacados na imagem. Já os semissólidos são definidos como uma área focal, sendo representados em um exame de TC, com uma atenuação ligeiramente "turva", onde o parênquima pulmonar, os vasos e as vias aéreas ainda estão visíveis (CHEN et al., 2021).

O grupo dos nódulos semissólidos é dividido em duas subcategorias: não sólidos (também conhecidos como *ground glass nodule*, GGN) e parcialmente sólido ou misto, que consiste de partes sólidas e partes opacas/foscas (*ground glass opacities*, GGO), assim como apresentado na Figura 3.

De acordo com o *International Early Lung Cancer Action Project* (I-ELCAP)¹, 81% de todas as detecções positivas são nódulos sólidos e apenas 19% das mesmas correspondem a nódulos semissólidos, indicando a baixa ocorrência desse tipo de nódulo (YOUNG; HOPKINS, 2012; NAIR, 2010; MCWILLIAMS et al., 2013). Por outro lado, os nódulos semissólidos são

¹ I-ELCAP <<https://www.ielcap.org/>>

Figura 3 – Destaques de um exame de tomografia computadorizada, representando os três tipos de nódulos: a) sólido b) parcialmente sólido ou misto c) não sólido



Fonte: Elaborada pelo autor adaptada de Lassen et al. (2015)

os que demonstram maiores taxas de malignidade. A cada 44 detecções positivas de nódulos semissólidos, 15 dessas, ou seja, 34% são lesões malignas, enquanto somente 7% (14 a cada 189 detecções positivas de nódulos sólidos) são lesões que apresentam um grau de malignidade devido a este outro tipo de nódulo.


A primeira tarefa para a discriminação e classificação de um nódulo entre benigno e maligno, é a diferenciação de transiente e persistente. Lesões transientes são lesões que desaparecem ao longo do tempo e são benignas, enquanto as lesões persistentes são lesões que persistem ao longo do tempo se tornando, na maioria dos casos, em lesões malignas (CHUNG et al., 2018). De acordo com a literatura, a capacidade visual de radiologistas experientes em diferenciar nódulos semissólidos entre persistentes e transientes, é razoável e somente para nódulos com diâmetros maiores que 10 mm. Ainda de acordo com Chung et al. (2018), 38% a 70% dos nódulos semissólidos tendem ser nódulos transientes, o que reitera a importância de se detectar e segmentar corretamente esse tipo de nódulo, a fim de se discriminar o nódulo entre potencialmente maligno e eventualmente benigno, o mais precoce possível.

2.3 Tomografia Computadorizada

Tomografia Computadorizada (TC) é uma técnica não-invasiva realizada no processo de aquisição de imagens médicas (KOCKELKORN, 2017). A TC cria detalhadas imagens 3D por combinação das informações de várias imagens 2D no plano axial, mas que através da reconstrução da imagem, permite a visualização em outros planos de cortes. Um exemplo de exame de TC é apresentado na Figura 4. Desde sua introdução em 1970, a TC se tornou uma das técnicas mais comuns para aquisição de imagens médicas, e vital para o diagnóstico de várias doenças pulmonares. De acordo com o Cadastro Nacional de Estabelecimentos de Saúde (CNESNET, 2022), existem no Brasil 1,21 tomógrafos para cada 100 mil habitantes e em Junho

de 2020, 160.806 exames de TC do tórax foram realizados.

Figura 4 – Imagens de seções do pulmão. (a) Plano de corte em relação ao corpo humano; (b) seção sagital; (c) seção axial; e (d) seção coronal



Fonte: Elaborada pelo autor adaptada de Cavalcante (2016)

Durante a aquisição da tomografia computadorizada, processo representado na Figura 5, uma fonte de raio-X rotaciona, com movimentos espirais de 360 graus contínuos em torno do paciente, para detecção e cálculo da atenuação de raios-X absorvidos no lado oposto do paciente através de detectores de fótons, como é mostrado na Figura 5(a). Através de processamento computacional, finas seções 2D do objeto escaneado, também chamadas de *slice*, são reconstruídas através da projeção de imagens, e são empilhadas para formar a imagem 3D do objeto, assim ilustrado na Figura 5(b).

Os elementos cúbicos que compõem a matriz 3D de uma TC, são chamados *voxels*. Um *voxel*, ou menor elemento de volume, corresponde ao valor real de uma imagem em 3D (HOUNSFIELD, 1973). Cada *voxel* possui um valor que corresponde à atenuação média do órgão ou parte do corpo correspondente. A unidade para valores de *voxels* em imagens de TC é a unidade Hounsfield (UH). A escala UH é definida por


$$UH_{\text{tecido}} = 1000 \times \frac{(\mu_{\text{tecido}} - \mu_{\text{agua}})}{(\mu_{\text{agua}})} \quad (2.1)$$

em que μ_{tecido} é a medida do coeficiente de absorção, na região representada por um *voxel*, de um determinado tecido do corpo e μ_{agua} o coeficiente de absorção para a água.

Neste caso, o coeficiente de atenuação da água é estabelecida em 0 UH e o do ar em -1000 UH. Os valores da escala de densidade radiográfica apresentada em UH, para determinados tipos de tecidos e órgãos do corpo humano, são apresentados na Figura 6.

Os pulmões, com todas as suas estruturas, são perfeitamente adequados para imagens de TC, já que consistem de ar com densidade próxima à -1000 UH e tecido com densidade

Figura 5 – Representação do processo de aquisição de tomografia computadorizada. a) Ilustração dos movimentos da máquina e sentido de propagação dos raios-x, durante um procedimento típico de tomografia computadorizada. b) *Slices* de imagens empilhadas para formação da representação 3D



Fonte: Elaborada pelo autor adaptada de (THAN et al., 2017)

próxima à +100 UH. Esta faixa pode ser subdividida de forma que possibilite a identificação e caracterização de estruturas e regiões pulmonares. Deste modo, as principais faixas de densidade para caracterização de regiões pulmonares são (GEVENOIS et al., 1995):

- de -1000 a -900 UH para áreas hiperaeradas;
- de -900 a -500 UH para áreas normalmente aeradas;
- de -500 a -100 UH para áreas pouco aeradas; e
- de -100 a 100 UH para áreas não aeradas.


Por causa desse grande contraste, mesmo com uma baixa dose de radiação, exames de boa qualidade podem ser feitos.

2.4 Processamento Digital de Imagens

O corpo humano é composto por vários sistemas, como o sistema cardiovascular, o sistema nervoso e o sistema visual, por exemplo. Além disso, há ainda a existência de sentidos sensoriais clássicos como o olfato, paladar, visão, audição e tato, onde cada um é responsável por interpretar um tipo específico de informação com o objetivo de auxiliar a percepção do ser humano (RANGAYYAN, 2004).

Para algumas aplicações, a visão humana não possui uma precisão tão eficaz quanto à uma máquina virtual. Devido à significância e importância do papel que as imagens exercem

Figura 6 – Escala em unidades Hounsfield de estruturas do corpo humano



Fonte: Elaborada pelo autor adaptada de (Siemens Medical Solutions, 2013)

na percepção humana e com o objetivo do aprimoramento das mesmas para a interpretação humana, métodos e técnicas para análises automáticas por computador têm sido desenvolvidas, principalmente através do processamento e manipulação dessas imagens. O processamento digital de imagens (PDI) é definido por Bezdek et al. (2005) como o estudo de teorias, modelos e algoritmos de manipulação de imagens, abrangendo tópicos como digitalização, filtragem, segmentação, restauração e compressão.

O grande interesse em métodos de PDI é oriundo de duas principais áreas de aplicação: melhora das informações visuais para a interpretação humana e processamento digital de imagens para armazenamento, transmissão e representação. À vista disso, este capítulo tem vários objetivos: (1) salientar a definição de imagens bem como todos seus elementos constituintes, configurações, possibilidades principais e formatos e (2) ressaltar o objetivo da visão computacional e etapas fundamentais, enfatizando os processos e técnicas de segmentação de imagens como limiarização e crescimento de regiões.


A definição de imagem é muito bem representada por Gonzalez e Woods (2018) como sendo uma função bidimensional, $f(x,y)$, em que x e y são as coordenadas espaciais em um plano cartesiano, e a amplitude de f em qualquer par de coordenadas (x,y) é chamada de intensidade luminosa (brilho) ou nível de cinza da imagem nesse ponto. Uma imagem digital, considerada quando se há uma representação discreta de dados que processam informação espacial e de intensidade, é composta por um número finito de elementos com localizações e valores específicos, chamados de *pixels* (*picture elements*). Os índices x e y designam as linhas e as colunas da imagem e os *pixels* são referidos por seus índices 2D (x,y) .

Os valores que os *pixels* podem assumir, variam de acordo com o tipo de imagem, onde três desses são ilustrados na Figura 7. Segundo McAndrew (2004), no caso mais simples, cada posição de *pixel* contém somente um valor numérico representando o nível de sinal ou resposta física no espaço real bidimensional (2D) naquele ponto da imagem. Essas são as imagens binárias

(Figura 7(a)) representadas por uma simples sequência de bits, que alocam um valor numérico do conjunto $\{0, 1\}$, nesse caso, podendo assumir apenas 0 (preto) ou 1 (branco). Imagens de intensidade ou escala de cinza (Figura 7(b)), são caracterizadas por atribuir a cada *pixel* um valor numérico entre 0 (preto) e 255 (branco), por exemplo, intervalo este limitado pela resolução de bit da imagem.

Por outro lado, no processamento de imagens coloridas, a representação usada para armazenar as cores e especificar o número e a natureza dos canais de cor é geralmente referida como espaço de cor. Imagens RGB (Figura 7(c)) são matrizes tridimensionais (3D) caracterizadas como três planos 2D distintos, cada um correspondendo a um dos três canais de cor - vermelho(R), verde (G), e azul (B). O modelo RGB é o espaço de cor mais utilizado para a representação de imagens digitais, pois corresponde às três cores primárias que são misturadas para exibição de imagens em um monitor ou dispositivo similar (SOLOMON; BRECKON, 2013).

Figura 7 – Representação de uma imagem em diferentes espaço de cores. Representação no espaço de cor (a) binário; (b) tom de cinza; (c) RGB




Fonte: Elaborada pelo autor

A principal grandeza que especifica a resolução de uma imagem, é a resolução espacial. A quantidade de dados armazenados em cada *pixel* junto ao tamanho da grade (ou malha) de *pixels* bidimensionais, determinam a resolução espacial e a quantização, que é o processo de representar os valores de uma amostra de sinal ou imagem usando um conjunto infinito de valores permitidos (RANGAYYAN, 2004). De acordo com Solomon e Breckon (2013), esta grandeza é referida como resolução de *pixel* ou resolução digital da imagem, comumente denotada como colunas (C) $\times$ linhas (L) sendo alguns exemplos ilustrados na Figura 8. Com *pixels* muito grandes, obtém-se uma baixa resolução espacial com uma pobre representação da imagem (Figura 8(d)). À medida que os *pixels* se tornam menores, há um efeito contrário dando a impressão de uma imagem espacialmente contínua, devido ao fato dos *pixels* terem se tornado menores que a resolução espacial do sistema visual humano (Figura 8(a)).

A necessidade de métodos eficientes de exibição, armazenamento e transmissão de imagens, levou ao desenvolvimento de formatos padronizados de imagens digitais. Há um grande número de formatos de imagens reconhecidos, onde os mais comuns são: GIF, JPG, BMP, PNG e TIFF, cada um com suas propriedades e conveniência a uma certa aplicação própria da indústria. A indústria médica, por sua vez, utiliza diversos exames por imagem, cada um com suas propriedades específicas. Nesta área, as imagens DICOM (*Digital Imaging and*

Figura 8 – Efeitos da amostragem na aparência e qualidade de uma imagem. (a) 225×250 pixels; (b) 112×125 pixels; (c) 56×62 pixels; (d) 28×31 pixels. Todas as quatro imagens têm 256 tons de cinza e 8 bits por pixel



Fonte: Rangayyan (2004)

Communications in Medicine) são de especial interesse porque podem ser fornecidas por uma variedade de dispositivos de imagem, e se tornou um padrão, principalmente para imagens de TC (CLUNIE, 2021; FAJAR et al., 2021).


Imagens que seguem o protocolo DICOM, principalmente imagens médicas de TC, além de propiciar um padrão para o arquivamento, manuseio, impressão e transferência de dados entre dispositivos, contém informações que descrevem as imagens, os metadados. Informações referentes à identificação do paciente e do exame, aliadas ao processamento de imagens e à visão computacional, são ferramentas muito importantes para o auxílio ao diagnóstico médico em imagens de TC quanto à doenças pulmonares (FEDOROV et al., 2020; SUJI et al., 2020).

2.5 Visão Computacional

O principal objetivo da visão computacional (VC) é utilizar computadores para emular a visão humana, incluindo principalmente a capacidade de fazer inferências, havendo assim muita sobreposição com o campo de processamento digital de imagens. Sistemas de VC utilizam várias técnicas do PDI para automatizar o processo de percepção visual, com a finalidade de segmentar, reconhecer e/ou identificar detalhes de regiões de interesse em uma determinada imagem, de modo automático ou semiautomático (BEZDEK et al., 2005). Estes sistemas são divididos basicamente em 5 etapas: aquisição, pré-processamento, segmentação, extração de atributos e reconhecimento e interpretação (GONZALEZ; WOODS, 2018).

Considerando a breve exposição do sistema de aquisição de exames de TC da seção anterior, esta dissertação concentra-se nas etapas de pré-processamento e segmentação e suas técnicas utilizadas. Um sistema típico de VC está ilustrado na Figura 9.

Figura 9 – Sistema de visão computacional típico



Fonte: Elaborada pelo autor

A aquisição de imagens, primeiro passo fundamental em PDI, pode ser tão simples quanto receber uma imagem em formato digital assim como a formalização de um modelo matemático. De qualquer forma, na maioria das vezes envolve um tratamento preciso, como por exemplo o redimensionamento de imagens. A etapa de aquisição abordada nesta dissertação trata de imagens de TC no protocolo DICOM, sistemas já abordados anteriormente.

Segundo Gonzalez e Woods (2018), três tipos de processamentos computacionais são levados em consideração:

- processos de níveis baixos: pré-processamento de imagens para redução de ruído, realce de contraste e aguçamento de imagens.
- processos de níveis médios: tarefas como a segmentação (separação de uma imagem em regiões ou objetos, a descrição desses objetos e a classificação/reconhecimento de objetos individuais.
- processos de níveis altos: análise de imagens para “dar sentido” a um conjunto de objetos reconhecidos.

A etapa de pré-processamento consiste na aplicação de técnicas de filtragem objetivando a redução de ruídos ou adequação da imagem para melhor realce e para etapas posteriores de um sistema de VC, como a etapa de segmentação. Além da filtragem e do realce de imagens, de acordo com Gonzalez e Woods (2018), técnicas de restauração, o processamento de imagens coloridas e multirresolução, compressão e processamento morfológico, se encaixam no sistema típico de VC como técnicas de pré-processamento lidando com a melhora visual de uma imagem.


O procedimento de segmentação é, sem dúvidas, uma das tarefas mais difíceis no PDI e etapa de VC com ampla variedade de aplicações. Segmentação é o processo de subdividir uma imagem em seus componentes ou objetos constituintes de interesse, e tem o objetivo básico de

separar a imagem em regiões mutuamente exclusivas que possam ser rotuladas de forma coerente (SOLOMON; BRECKON, 2013; SOILLE, 1999).

Depois de ter segmentado uma imagens em regiões, tem-se uma etapa final de extração de atributos e descrição. Quando o objetivo é obter informações numéricas, realiza-se a extração de atributos e características. Extrair características em uma imagem, evidencia as diferenças e similaridades entre os objetos. Nesta etapa são realizadas medidas na imagem e através dessas medidas, os grupos de pixels são descritos por atributos característicos, gerando dados quantitativos para o objeto final (GONZALEZ; WOODS, 2018).

Em geral, a extração de atributos pode ser dividida em duas etapas: rotulação e atributos da imagem. A rotulação é a etapa intermediária que dá um rótulo (ou *label*) para cada grupo de *pixels* agrupados, permitindo posteriormente o cálculo de um parâmetro específico para a região. Já para a etapa de atributos da imagem, temos dois tipos de medida: medidas de campo (*field features*) e medidas de região (*region features*). As medidas de campo se referem ao todo, como na contagem e área total de objetos, por exemplo, gerando um valor por medida. As medidas de região se referem aos objetos individualmente, ou seja, para cada objeto na imagem é extraído uma parâmetro, como tamanho, forma e posição (SOLOMON; BRECKON, 2013). Neste trabalho, devido a significância de calcular e comparar o volume ou a massa de um nódulo, são extraídos para cada lesão seu volume, sua área e diâmetro. A Figura 10 apresenta um exemplo da técnica de rotulação e a Figura 11 os principais atributos de região que podem ser extraídos de uma imagem.


Figura 10 – Imagem "rotulada": (a) Imagem original compsta por regiões conjuntas de *pixels*. (b) Imagem final após o processamento de rotulação. As cores são utilizadas para auxiliar na visualização das regiões



Fonte: Elaborada pelo autor

Isto posto, as etapas fundamentais e ideias centrais deste trabalho se concentram nas etapas de pré-processamento e segmentação e suas técnicas utilizadas. Dessa forma, a seguir são descritos os principais objetivos, dificuldades, tipos e técnicas de segmentação, enfatizando as quais a metodologia aqui proposta utiliza como base.

Figura 11 – Principais atributos de região, ou seja, dos objetos independentes presentes na imagem



Fonte: Elaborada pelo autor

2.5.1 Segmentação

Em uma imagem segmentada, os elementos primários da imagem não são mais os *pixels*, mas o conjunto de *pixels* conectados. Em geral, a segmentação completamente autônoma de imagens não triviais é, dentre as etapas de um sistema típico de VC, uma das tarefas mais difíceis e permanece sendo um ativo campo de pesquisa em PDI, com aplicações em constante evolução e atualização. Os erros cometidos nesta fase afetarão todas as etapas subsequentes (ALMEIDA, 2019).

A segmentação de imagens é, em geral, abordada de duas maneiras: descontinuidade e similaridade. Segmentação por descontinuidade e/ou métodos de contorno/fronteira, tem por base a detecção de bordas para identificação de fronteiras em regiões, a fim de delimitar o objeto. As abordagens da segunda categoria, segmentação por similaridade, baseiam-se na alocação de *pixels* a uma dada região de acordo com o grau de similaridade entre eles, como cor, forma ou características do objeto (SILVA FILHO, 2018). Dentre as técnicas de segmentação com essa abordagem, destacam-se a limiarização e o crescimento de regiões.

2.5.1.1 Limiarização

A limiarização é um dos métodos mais simples e populares para obter a segmentação de uma imagem. O resultado dessa abordagem gera uma imagem em que os *pixels* pertencentes a objetos têm valor 1 e *pixels* pertencentes ao fundo têm o valor 0, sendo esse processo chamado de binarização. O objetivo da limiarização é segmentar uma imagem em regiões de interesse e remover todas as outras regiões consideradas não essenciais (WASHINGTON et al., 2001).

Os métodos de limiarização mais simples usam um único limite (*threshold*) para isolar objetos de interesse. Em muitos casos, no entanto, nenhum limite único fornece resultados satisfatórios de segmentação, sendo tarefas que requerem total automação, exigindo assim critérios mais complexos para seleção do valor de *threshold*. De acordo com Solomon e Breckon (2013), há algumas limitações associadas à aplicação de limiar global: a não consideração das relações espaciais entre os *pixels*, a não sensibilidade à variações de iluminação e a restrição de aplicação somente em imagens que são facilmente divisíveis em dois planos de intensidade


diferentes. A Figura 12 representa o processo de limiarização com variações no valor de *threshold*.

Por conseguinte, diversos autores propuseram outras abordagens de limiarização através da seleção automática do *threshold*, assim como limiares adaptativos. Os primeiros trabalhos de limiarização global ótima são exemplificados em Chow e Kaneko (1972), Sahoo, Soltani e Wong (1988) e Lee, Yoon Chung e Park (1990). As aplicações deste método apresentam limitações em decorrência da necessidade de se estimar funções de densidade de probabilidade. Otsu (1979) abordou uma alternativa de combinação de desempenho, precisando apenas de um dos histogramas das imagens, baseada na busca exaustiva do valor de limiar que maximiza a variância entre os objetos da imagem. Além disso, técnicas de pré-processamento também são utilizadas para melhorar a limiarização global, como a suavização (SAUVOLA; PIETIKÄINEN, 2000) e a informação das bordas (LIANG et al., 2000; CHAN; KARL; LEES, 2000).

Aplicações que requerem mais de dois limiares geralmente são resolvidas com mais do que dois valores de intensidade, ou seja, utilizando também descritores adicionais como a cor, por exemplo. Para esses casos, Yin e Chen (1997), Liao, Chen e Chung (2001), Zahara, Fan e Tsai (2005) utilizam limiares múltiplos e Parker (2010) e Delon et al. (2007) abordam o uso de limiares variáveis.

Na metodologia proposta neste trabalho, o processo de limiarização é utilizado para calcular dois valores de intensidade que servem de parâmetro para a etapa de crescimento de regiões, com o objetivo de separar região nódulo e região não nódulo. A definição desses dois valores de intensidade e valores de limiar, são realizadas através da análise de histograma aplicados à região de interesse.

Figura 12 – Processo de limiarização. (a) Imagem original; (b) segmentação por limiarização; (c) *threshold* muito baixo e (d) *threshold* muito alto



Fonte: Sonka, Hlavac e Boyle (1993)

2.5.1.2 Crescimento de Regiões

O crescimento de regiões é uma abordagem à segmentação baseada no agrupamento de *pixels* em regiões maiores, segundo algum critério de similaridade pré-definido. O procedimento inicia-se a partir de um *pixel* chamado de semente, distribuído aleatoriamente na imagem, que vai comparando e agregando *pixels* adjacentes espacialmente conectados com o *pixel* semente, e expandindo a região até que não haja mais *pixels* que satisfaçam o critério de inclusão na região referida Gonzalez e Woods (2018), Hojjatoleslami e Kittler (1998).

As vantagens dessa abordagem são, de acordo com Rahman et al. (2016), simplicidade, flexibilidade na definição de critérios e do *pixel* semente, além de acurácia significativa na segmentação de imagens ruidosas. Quanto às desvantagens, os autores relatam uma sobre segmentação devido a variação de intensidade nas imagens, bem como um elevado custo computacional.

Seja R uma região de N *pixels* vizinhos de uma semente com nível de cinza específico e $I[x, y, z]$ a intensidade da coordenada 3D x, y, z , define-se a média da região $\bar{X}$ e dispersão S^2 por (SHAPIRO; STOCKMAN, 2001):

$$\bar{X} = \frac{1}{N} \sum_{[x,y,z] \in R} I[x, y, z] \quad (2.2)$$

e

$$S^2 = \sum_{[x,y,z] \in R} (I[x, y, z] - \bar{X})^2 \quad (2.3)$$

Diversos trabalhos de segmentação manual e automática de nódulos pulmonares, fazem uso da técnica de crescimento de regiões. Dentre esses, Kim et al. (2016) aplicam CR para a segmentação 2D, enquanto Lassen et al. (2015), Scholten et al. (2015), Yaguchi et al. (2015) expandem para uma aplicação 3D, ambos de forma manual. Por outro lado, devido à dificuldade de se obter imagens em três dimensões, um número menor de técnicas aplicam CR 3D, é o caso de Lopez Torres et al. (2015), Dong et al. (2020).

Na metodologia proposta neste trabalho, após o cálculo dos dois limiares de intensidades típicas das regiões nódulo e não-nódulo anteriormente na etapa de limiarização, o crescimento de região é executado a partir de uma semente. Este processamento é responsável por separar o nódulo do parênquima pulmonar que o envolve, mas também por evitar vazamentos da região do nódulo junto à parede pulmonar e/ou vasos sanguíneos. O resultado esperado é uma região inicial do nódulo ainda podendo conter regiões de parede pulmonar e vasos sanguíneos anexos ao nódulo.

2.5.2 Morfologia Matemática ou Processamento Morfológico de Imagens

A palavra morfologia significa o estudo de formas ou estruturas espaciais (SOILLE, 1999). De acordo com Washington et al. (2001), a morfologia matemática é a parte do PDI que se preocupa com a filtragem de imagens e a análise geométrica por elementos estruturantes. Em processamento digital de imagens e dentro da Visão Computacional, técnicas morfológicas englobam um grande conjunto de ferramentas para extração de descritores e características de interesse em uma imagem, com base em propriedades de forma ou contorno.

As técnicas que serão descritas a seguir, são técnicas altamente relevantes para atividades de pré-processamento como redução de ruídos da imagem, ou pós-processamento como extração


de componentes conectados e fecho convexo (*convex hull*) e podem ser usadas como base para o desenvolvimento de procedimentos de segmentação de imagens com várias aplicações.

No PDI, nos referimos aos *pixels* em uma imagem binária como *pixels* de primeiro plano (*foreground*) aqueles que têm valor lógico 1, e como *pixels* de segundo plano (*background*) da imagem, aqueles que têm valor lógico 0. O efeito de qualquer processo morfológico se reduz à determinação dos *pixels* de primeiro plano que se tornam de segundo plano e dos *pixels* de segundo plano que se tornam de primeiro plano. Essas determinações dependem de três fatores: a imagem, o tipo de operação morfológica e do elemento estruturante (GONZALEZ; WOODS, 2018).

Operadores morfológicos visam extrair estruturas relevantes da imagem considerando como um conjunto por meio de sua representação gráfica (SOILLE, 1999). Elementos estruturantes são, de acordo com Gonzalez e Woods (2018), pequenos conjuntos ou sub imagens usadas para examinar uma imagem buscando propriedades de interesse. Esse elemento é a entidade que determina, dado um *pixel* de primeiro/segundo plano, que *pixels* vizinhos terão ou não seu valor alterado. Boa parte da complexidade e esforço de um processamento morfológico, traduz-se na escolha do elemento estrutural apropriado à aplicação ou ao objetivo. Alguns exemplos de elementos estruturantes estão ilustrados na Figura 13.

Na metodologia proposta neste trabalho, a remoção de parede pulmonar e de vasos anexos ao nódulo pulmonar, ou seja, a reconstrução dos limites da lesão e refino da mesma, é possível através das operações morfológicas de erosão, dilatação, abertura e fechamento.

Figura 13 – Exemplos de elementos estruturantes, onde cada quadrado indica um membro do ES. Os pontos indicam os centros dos ESs



Fonte: Elaborada pelo autor adaptada de Gonzalez e Woods (2018)

2.5.2.1 Erosão e Dilatação

Os dois principais operadores morfológicos no PDI e que definem a álgebra da morfologia matemática, são erosão e dilatação, de tal forma que muitos dos algoritmos morfológicos podem ser compostos pela combinação dessas operações primitivas (BANON; BARRERA, 1994). Os conceitos morfológicos introduzidos neste trabalho, podem ser formulados em termos do espaço euclidiano n -dimensional, E^n . No entanto, nosso interesse está nas imagens binárias, cujos componentes são elementos representados no espaço z^2 , se tratando assim de morfologia matemática binária. Dessa forma, considerando uma imagem genérica A e um

elemento estruturante arbitrário B , com A e B como conjuntos de z^2 , a operação de erosão binária de A por B , denotada por $A \ominus B$, pode ser definida pela seguinte expressão (GONZALEZ; WOODS, 2018):

$$A \ominus B = \{ z \mid (B)_z \subseteq A \} \quad (2.4)$$


indicando que a erosão de A por B resulta no conjunto de todos os pontos z de forma que B , transladado por z , está contido em A . A Figura 14 mostra um exemplo de erosão, demonstrando que a erosão diminui ou afina os objetos em uma imagem binária, ou seja, os detalhes da imagem menores que o elemento estruturante são removidos da imagem.

De funcionamento similar, a operação de dilatação binária de A por B , denotada por $A \oplus B$, é definida como

$$A \oplus B = \{ z \mid (\hat{B})_z \cap A \neq \emptyset \} \quad (2.5)$$

resultando no conjunto de todos os deslocamentos z , de forma que B e A se sobreponham pelo menos por um elemento. Como ilustrado na Figura 15, ao contrário da erosão, que diminui e/ou afina, a dilatação “aumenta” ou “engrossa” os objetos em uma imagem binária.

Figura 14 – Erosão de um conjunto X por um elemento estruturante em disco B




Fonte: Elaborada pelo autor adaptada de Soille (1999)

Em síntese, no funcionamento da erosão e da dilatação o elemento estruturante é deslizado sobre a imagem, de modo que seu *pixel* central seja sucessivamente sobreposto a cada *pixel* de primeiro ou segundo plano, e seu novo valor depende dos valores dos *pixels* da vizinhança definida pelo elemento estruturante. A combinação de operadores morfológicos pode formar novas funções de grande importância no realce de imagens, por exemplo, o gradiente morfológico, abertura, fechamento, dentre outras.

2.5.2.2 Abertura e Fechamento

Dilatações e erosões são geralmente empregadas em pares e o resultado dessas operações aplicadas sucessivamente resulta na eliminação de detalhes da imagem menores do que o elemento estruturante (WASHINGTON et al., 2001). A operação de erosão em uma imagem não apenas remove todas as estruturas que não podem conter o elemento estruturante, como também diminui, afina todos os outros. A busca por um operador que consiga recuperar a maioria das estruturas perdidas pela erosão, levou a definição do operador de abertura morfológica. De forma

Figura 15 – Dilatação de um conjunto X por um elemento estruturante em disco B 

Fonte: Elaborada pelo autor adaptada de Soille (1999)

análoga, também foi definido o operador de fechamento morfológico, com a ideia de recuperar a forma inicial de estruturas da imagem que foram dilatadas (SOILLE, 1999).

Abertura é o nome dado à operação morfológica de erosão seguida de dilatação com o mesmo elemento estruturante, resultando, na maioria das vezes, em objetos com contorno suavizado e na remoção de finas saliências adjacentes em um objeto. Denota-se a abertura de A pelo elemento estruturante B como (GONZALEZ; WOODS, 2018):

$$A \circ B = (A \ominus B) \oplus B \quad (2.6)$$


indicando que a abertura de A por B é a erosão de A por B , seguida de uma dilatação do resultado por B . A abertura de um conjunto X em termos do elemento estruturante B é mostrada da Figura 16. Invertendo as operações binárias, temos o fechamento, como ilustrado na Figura 17. O fechamento tende a suavizar contornos, mas, diferentemente da abertura, junta as discontinuidades, eliminando pequenos buracos e preenchendo as lacunas em um contorno. O fechamento de A pelo elemento estruturante B , pode ser expresso da seguinte forma (GONZALEZ; WOODS, 2018):

$$A \bullet B = (A \oplus B) \ominus B \quad (2.7)$$


Um outro algoritmo morfológico que satisfaz as propriedades de um fechamento é o fecho convexo ou *convex hull*. Um conjunto A é considerado convexo se o segmento de linha reta que une quaisquer dois pontos em A ficar totalmente dentro de A (GONZALEZ; WOODS, 2018). Para Goutsias, Vincent e Bloomberg (2006), fecho convexo de um conjunto X corresponde ao menor conjunto convexo que contém X , com várias maneiras de se obtê-lo. A Figura 18 ilustra o procedimento de fechamento convexo.

2.5.2.3 Análise de Componentes Conectados

O conjunto de todos os *pixels* conectados a um dado *pixel* é denominado componentes conectados do *pixel* em questão, onde a análise se dá por meio da atribuição de rótulos individuais a objetos conectados em uma imagem binária. De acordo com Gonzalez e Woods (2018), a extração desses componentes conectados se torna, em problemas de processamento

Figura 16 – Abertura de um conjunto X por um elemento estruturante em disco B 

Fonte: Elaborada pelo autor adaptada de Soille (1999)

Figura 17 – Fechamento de um conjunto X por um elemento estruturante em disco B 

Fonte: Elaborada pelo autor adaptada de Soille (1999)

digital de imagens, uma operação essencial e muito comum para muitas aplicações de inspeção automatizada.

A identificação dos componentes conectados também fornece o número de objetos em uma imagem, de modo que cada objeto pode ser analisado separadamente e suas propriedades geométricas listadas como tamanho, forma ou posição. Abordagens de rotulagem padrão são fornecidas em Wilson e Ritter (2000). Seja H um conjunto contendo um ou mais componentes conectados que formam uma imagem I , cujos elementos possuem valor 0 (valores de fundo) e 1 (valores de frente). Desta forma, é atribuído o valor 1 para cada ponto que corresponde a um componente conexo em H . O objetivo é encontrar todos os componentes conectados na imagem I , partindo de I_0 . O seguinte processo iterativo cumpre esse objetivo (GONZALEZ; WOODS, 2018):

$$I_k = (I_{k-1} \oplus S) \cap H \quad k = 1, 2, 3 \quad (2.8)$$

em que S é o elemento estruturante e k a quantidade de iterações ao final do processo. Tem-se o conjunto com todos os elementos conectados quando $I_k = I_{k-1}$, e I_k contém todos os componentes da imagem de entrada. O procedimento é repetido para outro *pixel* de primeiro plano, mas que não pode pertencer a qualquer dos componentes conectados já identificados. O processo continua


Figura 18 – Representação da operação de *convex hull* em uma região côncava. (a) caracteres côncavos; (b) o menor conjunto convexo contendo cada caractere definindo o *convex hull*



Fonte: Elaborada pelo autor adaptada de Soille (1999)

até que todos os *pixels* de primeiro plano tenham sido alocados a um componente conectado, como ilustrado na Figura 19.

Figura 19 – Extraíndo componentes conectados. (a) Elemento estruturante; (b) arranjo matricial contendo um conjunto com um componente conectado; (c) arranjo inicial; (d) a (g) vários passos na iteração da equação 2.8



Fonte: Elaborada pelo autor adaptada de Gonzalez e Woods (2018)

2.6 Segmentação de Nódulos Pulmonares

A taxa de sobrevivência e aumento das possibilidades de tratamento são consideravelmente maiores quando a doença pulmonar é identificada ainda em estágio inicial, ou seja, a detecção precoce e acompanhamento da taxa de crescimento da lesão, são fatores determinantes. Hoop et al. (2010) realizaram estudos que demonstraram que o acompanhamento da evolução do volume é muito mais significativo (em torno de 4 vezes) em relação à malignidade de um nódulo não sólido, comparado à evolução da massa e do diâmetro. Por outro lado, para que se consiga

calcular o volume da lesão, se faz necessário segmentá-la tridimensionalmente, processo este que manualmente leva, em média, de 5 a 10 minutos (HOOP et al., 2010), além de também apresentar uma certa subjetividade e dependência do operador. Dessa forma, para um aumento da taxa de sobrevivência e melhor auxílio ao diagnóstico e tratamento precoce, principalmente de nódulos pulmonares, a segmentação é imprescindível. Existem na literatura muitos métodos de segmentação para nódulos sólidos (MUKHOPADHYAY, 2016; FARAG et al., 2013; WANG et al., 2017; SHAKIBAPOUR et al., 2019; KUBOTA et al., 2011), mas, além desses métodos falharem quando aplicados em nódulos não sólidos, pouco se foi desenvolvido para esse tipo de nódulo, mesmo sendo estes os que apresentam maior taxa de malignidade.

O processo de segmentação de nódulos pulmonares, através de sistemas computacionais, pode ser executado de forma manual, semi-automática ou automática. A segmentação manual de uma estrutura volumétrica, como nódulos pulmonares, é um processo monótono e demorado, especialmente para grandes estruturas (HOOP et al., 2010). Dessa forma, a segmentação automática de nódulos, em exames de TC, se apresenta como uma técnica que possibilita a otimização de atividades nas rotinas clínicas. Há muitos métodos de segmentação automática para outras estruturas do corpo humano como vias aéreas (RIKXOORT et al., 2010; LEONARDI et al., 2021; MENG et al., 2017), coração (ZHENG et al., 2008; RICKE; POVINELLI; JOHNSON, 2005; AVENDI; KHERADVAR; JAFARKHANI, 2016), cabeça e pescoço (PERONI et al., 2012; MACCHIA et al., 2012; ANDREARCZYK et al., 2020), intestino (MEN; DAI; LI, 2017; JU et al., 2020) e até mesmo no pulmão como lobos e fissuras (RIKXOORT et al., 2010; LASSEN et al., 2012; ZHOU et al., 2006). Mas atualmente o processo de segmentação automática ainda não é tão difundido, devido a falta de confiabilidade por não ser acurado para todos os casos existentes.


Os desafios da segmentação de nódulos pulmonares dependem do tipo de nódulo. As possíveis classificações de nódulos quanto a textura, são mostrados na Figura 20. Para seres humanos, assim como para métodos de segmentação automáticos, nódulos sólidos com bordas bem definidas e rodeados por parênquima, são fáceis de segmentar. Se uma estrutura possui densidade similar à pleura ou à um vaso sanguíneo que seja adjacente ao nódulo, a detecção exata da borda do nódulo é um obstáculo, principalmente para o computador. Ainda mais desafiador é a delimitação dos nódulos não sólidos quando estes possuem densidade semelhante ao parênquima que o contorna. Dessa forma, o desenvolvimento de um método de segmentação automática para nódulos não sólidos para fortalecer ainda mais o auxílio ao diagnóstico médico, se faz necessário e oportuno.

Dentre as publicações a respeito de métodos para segmentação de nódulos não sólidos, algumas delas ainda utilizam métodos de inicialização manual, na tentativa de que sejam métodos que funcionem bem para todas as possíveis situações apresentadas na Figura 20.

Jung, Hong e Goo (JUNG; HONG; GOO, 2018) apresentam uma abordagem para segmentação de nódulos não sólidos que utiliza mistura gaussiana, um modelo de deformação multifásico assimétrico e uma análise de forma baseada na matriz hessiana. A inicialização da técnica é feita pela definição de um ponto, alcançando bons resultados na segmentação individual das componentes sólidas e não-sólidas do nódulo, e taxas de acerto de 78% para o banco LIDC e 85% para o banco de imagens privado do Seoul National University Hospital (SNUH). Yaguchi et al. (2015) também utilizam a técnica de mistura gaussiana no processo de segmentação, agora combinada com o processo de crescimento de regiões. A abordagem apresentada consegue segmentar nódulos sólidos e não sólidos, além de realizar a remoção de vasos por identificação de estruturas locais, processos esses ilustrados na Figura 21.

A técnica de crescimento de regiões (CR) é bastante utilizada em trabalhos de segmen-

Figura 20 – Diferentes tipos de nódulos pulmonares com o contorno da segmentação manual (vermelho) fornecido pelo banco de dados LIDC/IDRI. a) Nódulo sólido b) nódulo não sólido c) nódulo não sólido com o núcleo sólido d) nódulo sólido anexo à parede do pulmão e) nódulo sólido com vasos adjacentes f) nódulo não sólido com vasos adjacentes




Fonte: Elaborada pelo autor

tação de imagens, não só imagens médicas pulmonares, mas imagens genéricas. Kim et al. (2016) combinam o CR com técnicas de *level-set* e clusterização para a segmentação de nódulos, principalmente aqueles com formas e contornos mais complexos. Mas além de ser uma abordagem manual, ainda possui a desvantagem de todo o processo ser em duas dimensões (2D). O trabalho publicado por Scholten et al. (2015) combina o CR, agora em três dimensões (3D), e operações morfológicas no processo de segmentação, e consegue definir muito bem o diâmetro do nódulos e até mesmo diferenciar as componentes sólida e não-sólida do nódulo. Os resultados apresentados mostram segmentações ainda com inclusão de vasos e a escolha do *threshold* ainda é um obstáculo.

Do mesmo modo, Lassen et al. (2015) também utilizam o CR 3D que junto com as técnicas de componentes conectados e operações morfológicas, consegue segmentar tanto nódulos não sólidos puros como os semi-sólidos/misto com tempo de execução de aproximadamente 1 segundo. O processo de inicialização da técnica também é de forma manual e diferente das demais, que precisam de um ponto, um traço sobre o maior diâmetro do nódulo precisa ser criado pelo usuário, sendo essa sua maior desvantagem. A técnica produz 75% de sensibilidade aplicada à 59 nódulos do bando LIDC. Quatro casos resultantes do método de segmentação proposto pela autora, são representados na Figura 22.

Outras técnicas também são empregadas no processo de segmentação de nódulos não sólidos, ainda com inicialização de forma manual. Em seu trabalho, Charbonnier et al. (2018)

Figura 21 – Remoção de vasos pulmonares e separação das componentes sólida e não-sólida presente em um nódulo semissólido misto




Fonte: Jung, Hong e Goo (2018)

abordam a classificação de *voxels* na identificação tanto da componente sólida como de vasos sanguíneos, utilizando para isso o classificador *kNN* sobre exames de CT do *Multicentric Italian Lung Disease* (MILD), apresentando 85% de acurácia. Outra técnica, é a empregada por Tsou et al. (2015) que utiliza o algoritmo *Anatomy Packing with Hierarchical Segments* (APHS). O algoritmo apresenta boa performance com estruturas altamente heterogêneas, conseguindo segmentar várias formas e texturas, além de realizar a segmentação por região e não por *pixel*. O método obteve valores de sensibilidade de 80,2% para todos os nódulos e 74,7% somente para nódulos não sólidos. Em contrapartida, a técnica é 2D.

Como a necessidade de um processo de segmentação automático, robusto e rápido, tem sido extremamente necessário para a detecção precoce da doença pulmonar e auxílio ao diagnóstico médico, técnicas e procedimentos automáticos têm sido publicados. Todas as técnicas de segmentação automática citadas, utilizam o banco de imagens LIDC. Algumas, junto com o LIDC, utilizam banco de hospitais privados, além do *Early Lung Cancer Action Project* (I-ELCAP), ITALUNG e ANODE9.

Savitha e Jidesh (SAVITHA; JIDESH, 2019) abordam em seu trabalho a utilização de um modelo baseado em contorno ativo junto à operações morfológicas para a etapa de segmentação, propondo assim um sistema completamente automático, que também realiza a detecção e classificação em nódulo ou não-nódulo. A abordagem apresenta baixo custo computacional mas tem dificuldades em segmentar nódulos justa-pleurais e um elevado tempo de segmentação, em

Figura 22 – Resultados do método de segmentação representado pelo contorno vermelho, e os contornos verde, amarelo, azul claro e azul escuro sendo as segmentações de referência




Fonte: Lassen et al. (2015)

torno de 76 segundos. Já em Li et al. (2016), a combinação do modelo baseado em contorno ativo é com *Wavelet* e com uma função de velocidade baseada em probabilidade. Essa combinação consegue lidar muito bem com objetos de bordas indefinidas, apresentando 85% de acurácia. A Figura 23 revela alguns resultados deste método de segmentação.

Um algoritmo amplamente utilizado na tarefa de segmentação de imagens, é o algoritmo de Fuzzy. Liu et al. (2015) abordam a segmentação de nódulos pulmonares, utilizando um método baseado no algoritmo *Fuzzy C-means* (FCM) combinado à clusterização e classificação de voxels. A técnica proposta tem rápida convergência, em torno de 5 segundos, mas não funciona bem para nódulos pequenos. Outra abordagem baseada no algoritmo de Fuzzy, é a apresentada por Dong et al. (2020), onde junto à técnica de CR e informações multimodais da própria TC, consegue obter um tempo de processamento de 16,38 segundos para a segmentação 3D do nódulo. A segmentação não funciona bem quando há componentes conectados ao nódulo e segmenta somente nódulos não sólidos puros.

Redes neurais também são uma estratégia utilizada na atividade de segmentação de nódulos pulmonares. Nesse tópico, Wu et al. (2020) propõe o modelo de rede neural tridimensional UNET otimizada pelo 3D *Conditional Random Field* (3D-CRF). Essa combinação de otimização acelera o decaimento da *loss rate* durante o treinamento da rede e melhora a acurácia do modelo. Por ser uma abordagem que precisa de muitas amostras, não obteve bons resultados para nódulos com diâmetros maiores que 30mm. Outra desvantagem é o elevado tempo de treinamento da rede, durando em torno de 10 horas.

Figura 23 – Resultados do método de segmentação representado pelo contorno vermelho, e os contorno amarelo sendo a segmentação de referência realizada por um radiologista



Fonte: Li et al. (2016)

Lopez Torres et al. (2015) usam como ferramenta de segmentação, dentro do completo sistema de detecção e segmentação abordado, o algoritmo *Channeler Ant Model* (lungCAM), a técnica de CR e operações morfológicas. A combinação proposta é completamente tridimensional e apresenta bons resultados independente do banco de imagens utilizado, e do tamanho do mesmo, resultando em 71,5% de sensibilidade para 8 falsos positivos. Porém, durante algumas etapas de filtragem, o processamento remove alguns nódulos não sólidos puros.

Em seu trabalho, Zhang et al. (2020) abordam a segmentação de nódulos não sólidos pequenos (diâmetros menor que 3mm). Para isso, integra um modelo de contorno ativo baseado no algoritmo *Markov Random Field Energy* (MRF) e em probabilidade *Bayesiana*. A técnica considera a vizinhança e estrutura espacial de *pixels*, além de considerar também a detecção de bordas. Mesmo assim, ainda apresenta resultados com vazamentos nas bordas e métrica de acurácia no valor de 74,4%.

Neste Capítulo foi realizada uma breve revisão da literatura sobre nódulos pulmonares, exames de TC, visão computacional e PDI com ênfase na etapa de segmentação de imagens e suas técnicas de forma ampla. Com base nos conceitos e características apresentadas neste Capítulo, assim como diversas metodologias que detalham a segmentação de nódulos pulmonares de forma manual e automática através crescimento de região e operações morfológicas, são elaborados e propostos processos para realizar a segmentação automática de nódulos pulmonares

não sólidos a partir de imagens de TC do tórax.

3 METODOLOGIA

O método de segmentação proposto neste trabalho baseia-se na abordagem de Lassen et al. (2015) para a segmentação de nódulos não sólidos a partir de imagens de TC do tórax. A metodologia apresentada por Lassen et al. (2015) mostra boa performance de tempo e assertividade para a segmentação dessa categoria de nódulos, mas não é uma abordagem automatizada, sendo necessário que o usuário considerando seu nível de experiência e sua análise subjetiva da região que seria uma lesão não sólida, identifique o *slice* com maior área de nódulo, verifique o maior diâmetro da região em que considera nódulo e crie um traço manualmente sobre o maior diâmetro da lesão. Dado que a tarefa de identificação das bordas de um nódulo não sólido é um dos principais motivos que tornam complexas a segmentação desses nódulos, uma inicialização através de um traço manual sobre o maior diâmetro do nódulo é passível de erros, dificultando ainda mais a segmentação desse tipo de lesão.

Nesse contexto, a metodologia proposta para realizar a segmentação de nódulos não sólidos em imagens de TC do tórax é descrita neste Capítulo, baseada nas técnicas abordadas no Capítulo 2. O método é capaz de realizar automaticamente não somente o processo de segmentação em si através de um método de segmentação menos complexo, mas também a diferenciação dos nódulos não sólidos de diferentes densidades.

Para a etapa de inicialização da segmentação, é indispensável a determinação das coordenadas tridimensionais (3D) de um ponto, sendo essa, para alguns casos, a menor interação do usuário. Desde que o ponto em questão esteja dentro do nódulo a ser segmentado, preferencialmente o mais próximo possível do centro do mesmo, há várias maneiras de defini-lo: (1) manualmente pelo usuário através de um clique, (2) resultado de uma etapa de detecção de candidatos, assim como (3) através de bancos públicos de imagens usados como referência que fornecem em seus metadados as coordenadas, definidas por especialistas, do centro de massa da lesão. A Figura 24 expõe uma visão geral das principais etapas realizada no método de segmentação. Nesta dissertação, a seguinte notação é utilizada para indicar qual exame e nódulo estão sendo analisados: nódulo 1 do exame 15 é denotado como caso 15-1.


3.1 Segmentação Automática de Nódulos Não Sólidos

Dado a definição das coordenadas 3D de um ponto, o algoritmo proposto para segmentação de nódulos não sólidos é compreendido das seguintes etapas que serão posteriormente descritas com mais detalhes: geração de raios fixos, seleção de raios adequados em decorrência da aplicação de uma ponderação de energia baseada na média de densidades, combinação de pares de coordenadas 3D dentro de um campo de busca, definição de uma região de interesse (ROI), análise de histograma e crescimento de região, remoção da parede pulmonar, remoção de vasos anexos e reconstrução do nódulo.

3.1.1 Conjunto Inicial de Raios

A etapa de geração de raios fixos, consiste na criação de segmentos de reta dado um ponto de origem O e um comprimento r . A distribuição dos raios utiliza coordenadas polares (r ; $teta$) que, na matemática, são um sistema de coordenadas 2D em que cada ponto no plano é determinado por uma distância r e um ângulo θ em relação a um ângulo fixo de referência, como ilustrado na Figura 25.

Figura 24 – Etapas do processo de segmentação para o eixo axial de um nódulo não sólido, caso 298-0. (a) Representação das quatro marcações originais dos radiologistas. (b) *Slice* 2D representando o centróide do nódulo. (c) Disposição de todos os raios criados sobre o nódulo. (d) Representação dos pontos de possíveis bordas que indicam os limites da lesão. (e) Seleção e armazenamento das coordenadas referentes as três maiores combinações de raios. (f) Região inicial do nódulo R_0 calculada a partir de um limiar baseado na operação de crescimento de regiões. (g) *Convex hull* do negativo da região R_0 . (h) R_{final} resultante da aplicação de operações morfológicas




Fonte: Elaborada pelo autor

Desta maneira, dado as coordenadas 3D da origem, um comprimento e o ângulo de passo, ou seja, a quantidade de raios que se deseja analisar, a **Figura 26** demonstra a distribuição equidistante dos raios sobre a imagem de um nódulo não sólido.


A quantidade de raios gerados e que se deseja analisar está diretamente relacionada com o ângulo de passo escolhido. Neste trabalho, foram testadas diversas situações para variados ângulos de passo, iniciado de 30° (0,52 radianos), ou seja, somente 12 raios, até o passo de 1° (0,017 radianos), gerando 360 raios. Após alguns testes e ensaios, escolheu-se, de forma empírica, utilizar o ângulo de passo igual a 5° (0,087 radianos), sendo então gerados 72 segmentos de reta que será contexto para o tratamento do segundo grupo de raios e cálculo do maior diâmetro da lesão. Outra informação importante para o processo de geração do primeiro grupo de raios, os raios fixos, é o comprimento dos mesmos. Também após alguns testes variando este valor, foi empiricamente definido como 12 pixels o comprimento dos raios para esta etapa. Considerando que o método utiliza um ROI de dimensões 32 × 32 pixels, os segmentos gerados ocupam 75% do raio da ROI.

Cada coordenada ao longo do raio está sobreposta à uma coordenada da imagem. Como bem exposto em seções anteriores, imagens médicas de TC no protocolo DICOM possuem, atribuída a cada pixel e/ou a cada voxel, um valor de intensidade de acordo com a densidade média em Unidade Hounsfield (UH). Sendo assim, um raio de comprimento k pixels conterá k informações de intensidade UH da imagem.

Figura 25 – Pontos no sistema de coordenadas polares com o polo O e o eixo L 

Fonte: Elaborada pelo autor

Figura 26 – Distribuição dos raios sobre (a) nódulo sintético e (b) nódulo real




Fonte: Elaborada pelo autor

Essas informações de intensidades associadas às coordenadas do raio e da imagem, que serão utilizadas para a segmentação e diferenciação dos nódulos não sólidos de diferentes densidades, são dispostas em uma estrutura de dados tabular bidimensional, os *dataframes*. Os dados são então organizados da seguinte forma: as linhas contém os índices de identificação dos raios e os valores de intensidade UH que o mesmo sobrepõe, e as colunas indicam os valores de comprimento ou número de *pixels* contidos no raio. A Figura 27 ilustra a disposição das linhas, colunas e dados de um *dataframe*.

A utilização de *dataframes* apresenta algumas vantagens pelo fato de serem estruturas semelhantes a uma tabela em um bancos de dados relacional, permitindo assim melhores otimizações e rápidas consultas, além da realização de cálculos muito rápidos sobre uma grande quantidade de dados. A seguir, as duas etapas do processo de segmentação, são operações

Figura 27 – Organização de uma dataframe e representação de suas partes



Fonte: Elaborada pelo autor

computacionais aplicadas sobre os dados de intensidade UH, coordenadas e índices dos raios dispostos em *dataframes*.

3.1.2 Conjunto de Raios Derivados

Uma das maiores complexidades da segmentação de nódulos não sólidos, está na estimação da borda desse tipo de lesão. De acordo com Chung et al. (2018), nódulos não sólidos são opacidades arredondadas ou irregulares bem ou pessimamente definidas medindo acima de 3 cm de diâmetro. Em Dong et al. (2020), nódulos vidro fosco (GGN) que são a principal ocorrência dos nódulos não sólidos, são descritos como nódulos com bordas altamente difusas e incertas, além de forma irregular. Portanto, a correta detecção das bordas desse tipo de nódulo se torna crucial para obtenção de resultados satisfatórios de segmentação.

O resultado do processo de geração do primeiro grupo de raios descrito anteriormente, são raios com tamanhos fixos igualmente distribuídos sobre o nódulo. Dado que parte destes raios contém coordenadas sobre regiões que pertencem ao nódulo, assim como regiões que não pertencem ao nódulo e, uma vez que espera-se delimitar a lesão através da detecção de suas bordas, elaborou-se uma ponderação de energia baseada na média das densidades equivalentes a cada coordenada do raio sobre a imagem, assim como disposto no *dataframe* resultante. As sequências de operações recursivas aplicadas a cada raio individualmente com o objetivo de limitar os raios e processar somente informações úteis (pertencentes ao nódulo) estimando assim a borda da lesão, é o que chamamos de ponderação de energia baseada na média das densidades. Diversos trabalhos utilizam a manipulação de raios, através de metodologias que envolvem Raios Ativos, pSnakes e Método de Contorno Ativo Radial 3D (MCAR3D) (ALMEIDA, 2019; DE ALEXANDRIA et al., 2014; ALMEIDA; CORTEZ; CAVALCANTE, 2017).

O tratamento para geração deste segundo grupo de raios proposto neste trabalho, também chamado de Média de Densidades Bidirecional Iterativa (MDBI), realiza o cálculo da média de

todos os valores de intensidade UH à direita e à esquerda de cada *pixel* pertencente ao raio em análise. Como evidenciado anteriormente, cada coordenada do raio possui, por estar sobreposto à uma coordenada da imagem, um valor de intensidade UH correspondente. Desta maneira, para cada linha do *dataframe* gerado, ou seja, para cada raio individual, aplica-se o MDBI às informações de intensidade arranjadas nas colunas e novos valores são gerados da seguinte forma, também ilustrado na Figuras 28 e 29:


- cálculo da média M_e de todos os valores à esquerda (exclusivo) da posição em análise (Equação 3.1), sendo T_r o tamanho do raio;
- cálculo da média M_d de todos os valores à direita (exclusivo) da posição em análise (Equação 3.2), sendo T_r o tamanho do raio;
- módulo das diferenças entre as médias M_e e M_d (Equação 3.3).

$$M_e = \frac{1}{C} \sum_{i=0}^{C-1} X_i \quad 1 \leq C \leq T_r \quad (3.1)$$

$$M_d = \frac{1}{T_r - C} \sum_{i=C+1}^{T_r} X_i \quad 0 \leq C \leq T_r - 1 \quad (3.2)$$

$$Dif = |M_e - M_d| \quad (3.3)$$


Figura 28 – Representação numérica da aplicação e cálculo do critério de parada e suas particularidades



Fonte: Elaborada pelo autor

Dentre os novos valores de módulos das diferenças, para esta análise de ponderação de energia e geração do segundo grupo de raios, são desconsiderados o primeiro e último valor. Isso devido ao fato de que por essas posições estarem nas extremidades do raio, não existem valores de intensidade à esquerda ou à direita, fazendo com que o cálculo de M_e e M_d resultem em zero, para o primeiro e último valor, respectivamente. Dessa forma, o módulo das diferenças para

Figura 29 – Representação sintética da aplicação da ponderação de energia baseada na média das densidades. (a) raio original de referência e (b) raio resultante pós ponderação de energia



Fonte: Elaborada pelo autor

estes dois casos não representa nenhuma informação de importância no processo de ponderação de energia.


De acordo com Gonzalez e Woods (2018) bordas são definidas como variações abruptas locais de intensidade e, na prática, imagens digitais apresentam bordas desfocadas e ruidosas com nível de ruído determinado principalmente pelos componentes eletrônicos do sistema de imagem. Imagens de TC do tórax e mais especificamente de nódulos pulmonares não sólidos, revelam bordas em um perfil em rampa na intensidade, ou seja, um ponto de borda é qualquer ponto contido nesta rampa, neste intervalo, como a borda da Figura 30. Sendo assim, por mais que a tarefa de detecção de bordas dos nódulos não sólidos busque uma variação abrupta de intensidade, há ainda um conjunto de pontos que são parte da transição de coordenadas pertencentes ou não pertencentes ao nódulo, que podem ser definidos como ponto de borda.

O cálculo do módulo das diferenças durante a aplicação do critério de parada MDBI, tem como objetivo gerar um segundo grupo de raios que a partir da mesma coordenada de inicialização do primeiro grupo de raios, processa, de forma iterativa, ponderações de energia com o objetivo de se estipular um possível ponto de borda dentro deste perfil em rampa para as intensidades. Desse modo, o ponto de borda escolhido, ou seja, o novo limite máximo do raio em análise, é definido como sendo a posição na qual o módulo das diferenças obteve o maior valor, simbolizando ali um potencial ponto de borda do nódulo.

3.1.3 Campo de Busca Suplementar

A aplicação do tratamento de ponderação de energia baseado na média das intensidades UH da imagem à todos os raios gerados, resulta, na maioria das vezes, em raios de tamanho menor do que o tamanho original e delimitados por um possível ponto de borda. Para a sequência do processo de segmentação, se faz necessário ter um traço sobre o maior diâmetro do nódulo,

Figura 30 – Modelo de borda com perfil de intensidade no formato de rampa



Fonte: Elaborada pelo autor adaptada de Gonzalez e Woods (2018)

ou seja, é preciso ter uma combinação de dois raios para que se consiga estimar um segmento (distância entre as duas extremidades do par de raios) que irá representar o maior diâmetro da lesão.

O objetivo desta etapa é definir uma região baseada no segmento suplementar ao raio em análise, para realizar uma sequência de cálculos utilizando a distância euclidiana entre as extremidades dos raios contidos nesta região e o raio de referência. Esta etapa fornece a capacidade para o método corrigir distorções na definição do centro do nódulo, já que por se tratar de regiões difíceis de se definir os limites da lesão, a identificação do centro, ou seja, da coordenada de inicialização do método e grupos de raios, é complexa e subjetiva. Portanto, sendo a referência um raio qualquer, computa-se o segmento suplementar (S) e, a partir deste segmento, são estabelecidas duas regiões R_1 e R_2 , configurando assim o campo de busca. O cálculo para geração das duas regiões é definido a seguir e ilustrado na Figura 31:


$$R_1 = S + \alpha\alpha = 30^\circ \quad (3.4)$$

$$R_2 = S - \beta\beta = 30^\circ \quad (3.5)$$

Com o campo de busca estruturado, todas as extremidades dos raios contidos na região delimitada por R_1 e R_2 são combinadas com a extremidade do raio de referência e a distância euclidiana é calculada entre as mesmas. Feito isto para todos os raios resultantes do tratamento de ponderação de energia, somente uma combinação de raios, a de maior distância euclidiana entre as extremidades, será mantida, armazenando-se assim as coordenadas de ambas extremidades relativas ao par de raios, ou seja, do segmento resultante como representado na Figura 32(a). O processo de manipulação de dados do dataframe, repete-se para todos os raios gerados, resultando assim em uma lista de coordenadas 2D e 3D de tamanho igual a metade do número de raios gerados, evidentemente, já que o objetivo é ter segmentos de reta compostos pela combinação de dois traços.

A lista com todos os pares de coordenadas combinados, amostra reproduzida na Figura 32(b), é ordenada de forma decrescente baseado no módulo da distância euclidiana entre as extremidades, uma vez que o maior diâmetro é o melhor segmento para a sequência do processo. Essa ordenação, em ordem decrescente, permite que um outro procedimento seja realizado e proposto como contribuição deste trabalho. Uma vez que as etapas seguintes do processo de

Figura 31 – Determinação do campo de busca. (a) definição das regiões R_1 e R_2 e (b) cálculo da melhor combinação baseado na distância euclidiana entre as extremidades dos raios dentro do campo de busca e a extremidade do raio de referência



Fonte: Elaborada pelo autor

segmentação são executadas a partir do primeiro segmento desta lista, pode ocorrer do mesmo se consideravelmente maior que a lesão e não representar o maior diâmetro ou até mesmo fazer com que outras estruturas, como vasos e parênquima pulmonar, sejam consideradas como região de nódulo e incluídas ao resultado final, ocasionando assim um resultado insatisfatório.


Para estas situações, algumas condições são criadas baseadas em uma série de fatores como a quantidade de *pixels* segmentados, não segmentados ou em objetos segmentados que apresentam diâmetros muito grandes ou muito pequenos, para que um resultado insatisfatório seja identificado. Caso uma das condições seja atendida, o segundo segmento da lista é enviado para o processo de segmentação e assim por diante, até um limite de 5 segmentos (quantidade esta definida por padrão) para não ocasionar um processo de segmentação demorado, e sim permitindo que rapidamente e transparente ao usuário, o método de segmentação consiga apresentar um resultado adequado e fiel à lesão real.

As seções a seguir totalizam as etapas do método automático proposto para segmentação de nódulos não sólidos. É importante reforçar que o método proposto neste trabalho não necessita de iteração com o usuário, ação essa que, assim como apresentado em Lassen et al. (2015), Charbonnier et al. (2018), Tsou et al. (2015), faz com que a segmentação seja semi-automática. Essa interação com o usuário, pode resultar em segmentações não confiáveis e/ou sub ou sobresegmentações, devido à complexidade de se definir manualmente o limite das bordas de um nódulo não sólido.

3.1.4 Região de Interesse e Análise de Histograma

Dado que uma lista das coordenadas que representam os maiores diâmetros do nódulo, organizadas de forma decrescente quanto ao comprimento, foi determinada após a execução das etapas descritas anteriormente, o segmento escolhido para a sequência do processamento é usado

Figura 32 – Seleção do raio resultante pós sucessivos cálculos de distância entre os raios em análise. (a) demonstração do raio resultante e (b) amostra da lista com as informações das combinações de raios ordenadas pelo comprimento



Fonte: Elaborada pelo autor


para definição de uma região de interesse (ROI) B .

O volume de interesse B , ilustrado na Figura 33 é definido com um cubo concêntrico ao ponto de origem usado para determinações dos raios, e aresta igual a 1,6x o comprimento do raio. Essa margem de 60% do comprimento do raio é usada para que a região B consiga compreender todo o volume do nódulo, incluindo toda sua extensão axial, assim como região não nódulo. O volume de interesse irá então fornecer informações úteis e necessárias para a diferenciação do nódulo ao parênquima e toda a sequência da segmentação será baseada em informações contidas na região.

Como a região de interesse gerada anteriormente contém região de nódulo e região de não nódulo e o objetivo é isolar somente a região pertencente ao nódulo, se faz necessário determinar intensidades típicas da lesão e do parênquima e assim calcular limiares ótimos para a etapa de crescimento de regiões a seguir e assim segmentar o nódulo do parênquima que o envolve. A determinação dessas intensidades típicas são realizadas através da análise de histogramas de regiões formadas através da manipulação de dilatações do traço no volume de interesse B .

Para definição da intensidade típica da lesão L , o traço usado no processo é dilatado por um voxel em todas as direções. Para a região resultante, idealmente abrangendo uma região mínima de nódulo, o histograma da mesma é plotado e suavizado, sendo L a intensidade correspondente ao argumento máximo do histograma. De forma semelhante é calculada a intensidade típica do parênquima P . O traço é dilatado por 4 voxels em todas as direções e a região resultante, idealmente abrangendo uma região máxima de nódulo, é subtraída do volume B . Ainda sobre os voxels remanescentes desta última operação, também são subtraídas todas as intensidades maiores que -200UH, garantindo assim que grande parte das intensidades restantes no volume B , representarão intensidades típicas do parênquima pulmonar. Por fim, as intensidades dos voxels remanescentes são plotadas e o histograma suavizado, sendo P a intensidade correspondente ao argumento máximo do histograma.

Figura 33 – Representação sintética do volume de interesse B composto por região de nódulo e região não-nódulo assim como outras estruturas presentes no parênquima pulmonar



Fonte: Elaborada pelo autor

3.1.5 Crescimento de Região

Definidas as intensidades típicas L e P , para a etapa a seguir de crescimento de região realizar o processo principal de segmentação, a mesma requer a determinação de dois valores de limiares ótimos, T_{menor} e T_{maior} . A escolha do valor para o menor limiar (T_{menor}) é crítica pelo fato de que o mesmo será responsável pela separação do nódulo com o parênquima pulmonar que o envolve, ou seja, é sobre o resultado de segmentação parametrizado por T_{menor} que os demais processamentos serão executados para refinamento do contorno da lesão. Entretanto, a escolha do valor para o maior limiar (T_{maior}) é menos crítica. T_{maior} é responsável por evitar vazamentos da região do nódulo junto à parede pulmonar e/ou à vasos sanguíneos, e tem um menor grau de criticidade em razão de que há etapas seguintes no processo dedicadas exclusivamente à remoção de parede pulmonar e de vasos anexos ao nódulo.

Dessa forma, o cálculo de T_{menor} pode resultar em dois valores de acordo com a equação a seguir:

$$T_{menor} = \begin{cases} \frac{P+L}{2}, & \text{se } \frac{P+L}{2} < -600 \\ -600, & \text{caso contrário} \end{cases} \quad (3.6)$$

Caso a média dos dois valores de intensidades típicas L e P seja maior que -600UH, T_{menor} é limitado a -600UH para evitar que a componente não sólida do nódulo fique total ou parcialmente fora do resultado de segmentação. Para o cálculo de T_{maior} , o valor fixo de 200UH é escolhido, assumindo assim o risco de que artefatos como parede pulmonar e vasos estejam incluídos no resultado inicial de segmentação, mas esperando-se que em etapas posteriores, os mesmos artefatos sejam removidos. De acordo com Lassen et al. (2015), T_{maior} foi estimado de forma empírica.

Isto posto, um crescimento de regiões 3D é realizado a partir do ponto central do traço (semente) e com T_{menor} e T_{maior} sendo os limiares balizadores, resultando assim em uma região

inicial do nódulo, mas que ainda pode conter regiões de parede pulmonar, vasos e outras estruturas anexas ao nódulo.

3.1.6 **Remoção de Parede Pulmonar**

Se partes de parede pulmonar ainda estiverem incluídas na região inicial do nódulo, a junção de três etapas é aplicada para a remoção da mesma. Primeiramente é definida a região N_c do parênquima pulmonar através da operação de análise de componentes conectados sobre o negativo da região inicial obtida pela etapa de crescimento de regiões. Assim, consegue-se obter uma região do nódulo já com um certo refino, definindo-se também a região N_1 resultante da subtração da região B com a região N_c . Por fim, para isolar completamente a região de nódulo da região de parede pulmonar, o *convex hull* de N_c é realizado resultando na região N_h , e a remoção acontece na operação de sobreposição das regiões N_1 e N_h .

A região N_2 resultante da concatenação das etapas descritas acima e ilustrada na Figura 34(b), não contém parede pulmonar, mas pode ainda conter resquícios da membrana externa que cobre o pulmão e separa o parênquima pulmonar da parede, também chamadas de pleura.

3.1.7 **Remoção de Vasos Anexos e Reconstrução do Nódulo**

A região N_2 ainda pode conter partes da pleura e também vasos anexos ao nódulo. Para remoção desses componentes e obtenção de um resultado mais fiel, duas ponderações precisam ser feitas: (1) o raio do nódulo é bem maior que o raio das outras componentes anexas à ele, e (2) as componentes anexas ao nódulo se conectam às bordas da região B e o nódulo não. Dito isso, a operação de abertura morfológica é aplicada sobre N_2 com o objetivo de desanexar todo e qualquer componente anexado ao nódulo, sendo pleuras ou vasos.


Entretanto, há uma variação de tamanhos tanto para os nódulos quanto para os vasos e não se pode aplicar uma abertura morfológica de força fixa padrão para todos os casos. A força da abertura deve ser adaptada automaticamente para que consiga remover os vasos e outras estruturas anexas ao nódulo, mas ao mesmo tempo manter os detalhes na borda do nódulo. Sendo assim, a escolha da força do processo de erosão que compõe a abertura morfológica baseia-se na aplicação da transformada da distância aplicado a partir do plano de fundo (*background*). A transformada, ou mapa da distância, gera uma imagem de mesmo tamanho da imagem de entrada e rotula cada *pixel* da imagem com a distância euclidiana até o *pixel* do plano de referência mais próximo, no caso do plano de fundo. O próximo passo é a execução de sucessivos crescimento de regiões, sendo o ponto de inicialização da técnica utilizado como semente, com o menor limiar sendo incrementado de acordo com os valores de distâncias, até a região resultante alcançar a borda de B . A força da erosão é então o último limiar (valor de distância) usado no crescimento de regiões antes da resultante encontrar o limite do volume B , fazendo com que o núcleo do nódulo seja mantido e as outras componentes anexas sejam retiradas.

A erosão aplicada cumpre o objetivo e consegue o resultado esperado, mas em contrapartida elimina também partes da borda do nódulo, prejudicando a definição do seu tamanho original. Para reconstruir os detalhes na borda do nódulo, o processo de dilatação, segunda etapa da abertura morfológica, é realizado. Novamente o mapa da distância é calculado e o limiar para o crescimento de regiões, calculado de maneira empírica, é $2mm$ maior do que a distância usada como limiar para o processo de erosão. Dessa forma, pequenas irregularidades presentes na borda do nódulo, são reconstruídas.

Finalmente, a interseção entre a região resultante do processo iterativo de abertura e a região N_2 é calculada, obtendo assim a região final da lesão N_{final} e o resultado final da

segmentação. O resultado final do caso 75-3 é exibido na Figura 34(c).

Figura 34 – Refino da região do nódulo. (a) nódulo original com as respectivas marcações dos 4 médicos especialistas. (b) segmentação resultante da etapa de remoção da parede pulmonar mas ainda com regiões de pleura. (c) segmentação final após etapa de remoção de vasos anexos e reconstrução do nódulo. Caso 75-3



Fonte: Elaborada pelo autor

3.2 Dados

A coleção de imagens de TCs utilizadas neste estudo foram extraídas a partir dos bancos de dados públicos e internacionalmente aceitos *Lung Image Database Consortium (LIDC)* e *Image Database Resource Initiative (IDRI)*. O banco de imagens do LIDC/IDRI é uma iniciativa do *National Cancer Institute (NCI)* fundado em 2004 em colaboração com vários hospitais, e consiste de 1018 exames de TCs com imagens no formato *Digital Imaging and Communications in Medicine (DICOM)* para diagnóstico e rastreamento de câncer de pulmão com lesões anotadas e marcadas, assim como os devidos arquivos em formato XML com informações referentes às lesões (ARMATO et al., 2011).

Cada um dos exames, coletados a partir de diferentes protocolos, centros médicos e equipamentos, foram submetidos a uma interpretação assíncrona por um total de 12 radiologistas em duas etapas e analisadas ao final por quatro experientes radiologistas. De acordo com (ARMATO et al., 2011), na primeira etapa os médicos realizaram marcações de lesões nódulos e não nódulos e do centro de massa das lesões consideradas nódulos. Na segunda etapa, todos os especialistas revisaram as marcações uns dos outros, podendo um radiologista manter, excluir ou adicionar novas regiões à marcação original do colega. Além das marcações das lesões, os especialistas atribuíram as mesmas valores de 1 a 5 para categorias como estrutura interna, calcificação, esfericidade, margem, malignidade e outros. Todo esse processo resultou em um banco de imagens público, robusto e que estimulou o desenvolvimento de vários métodos CAD, porém para o processo de segmentação, principalmente de nódulos não sólidos, resultou em marcações muito subjetivas, onde os médicos discordam bastante entre si quanto aos limites do nódulo e à todos os outros parâmetros específicos da lesão.

Com o propósito de melhorar o fluxo de trabalho associado ao LIDC/IDRI, este trabalho faz uso da biblioteca *pyl IDC* (HANCOCK; MAGNAN, 2016). Esta biblioteca Python fornece

informações a partir dos dados contidos nos arquivos XML de cada exame e dos atributos DICOM como ID do exame, *slice thickness* e *pixel spacing*. Além dessas, fornece também informações a partir dos dados das máscaras de segmentação produzidos pelos médicos especialistas, como textura, diâmetro, volume, área e coordenadas do centróide e da *bounding box* que circunscreve o nódulo.

Para obtenção de um conjunto de nódulos coerentes ao método proposto e execução dos experimentos expostos adiante, foram aplicados filtros e critérios de inclusão sobre os nódulos contidos no LIDC/IDRI. Para avaliar o método de segmentação proposto neste trabalho foram considerados nódulos onde a maioria dentre os especialistas, ou seja, pelo menos 3 desses, concordam que tal lesão é um nódulo. A classificação de textura segue o intervalo de 1 (*Non-solid/Ground glass opacity*) a 5 (*Solid*), e mesmo as categorias 2 (*Non-solid/Mixed*) e 4 (*Solid/Mixed*) sendo indefinidas pelo LIDC/IDRI, as mesmas ainda são usadas por alguns especialistas. Quanto às restrições referentes a textura, foram de interesse somente os nódulos com textura média menor ou igual a 3. Dessa forma, dado um número de anotações maior ou igual a 3 para um determinado nódulo, a média das 3 ou 4 texturas é calculada e caso este valor seja menor ou igual a 3, o nódulo passa a fazer parte do conjunto de dados aqui considerado.

O conjunto de dados resultante é então composto por 118 nódulos retirados de 86 exames, onde pelo menos três médicos especialistas concordam, e possui textura média menor ou igual a 3, ou seja, 1 = *Non-solid/Ground glass opacity*, 2 = *Non-solid/Mixed* ou 3 = *Part Solid/Mixed*. Para definir ainda mais o conjunto de amostras trabalhadas e dar mais detalhes ao conjunto de dados em que o método é aplicado, outras informações foram extraídas: os valores máximo, mínimo e médio para o *slice thickness*, diâmetro, área e volume, sendo os mesmos apresentados na tabela a seguir.

Tabela 2 – Informações dos valores máximo, mínimo e médio para o *slice thickness*, diâmetro, área e volume para os nódulos do conjunto de dados.

	<i>Slice Thickness</i> (mm)	Diâmetro (mm)	Área (mm ²)	Volume (mm ³)
Máximo	3,00	33,36	2811,95	7509,14
Mínimo	0,75	4,87	47,70	31,22
Média	1,58	11,30	384,33	578,04

Fonte: Banco de imagens LIDC/IDRI

3.3 Experimentos

Para análise e avaliação do método proposto, três experimentos foram estruturados. O método apresentado requer que as coordenadas 3D de um ponto próximo ao centro da lesão sejam fornecidas para que, a partir destas, decorra a sequência de etapas necessárias. Desde que todos os nódulos do LIDC/IDRI foram manualmente segmentados pelos médicos especialistas, por meio de uma interpretação assíncrona assim como descrito anteriormente, a média das coordenadas 3D dos centróides dessas máscaras de segmentações geradas por cada um dos médicos, foram armazenadas e utilizadas como ponto de inicialização do método de segmentação proposto.

Para comparação e análise do resultado de segmentação do método, além das próprias máscaras de segmentações individuais dos médicos especialistas, outras máscaras binárias de referência foram geradas. Com a organização destas outras máscaras binárias de referência, pretende-se ser possível estimar a efetividade da metodologia não apenas comparada à cada

médico individualmente, considerando que há uma disparidade considerável entre o nível de concordância entre os mesmos, mas também à outras três referências:

1. **Consensus**: volume de segmentação que inclui *voxels* pertencentes a 50% das máscaras individuais, ou seja, quando duas ou mais marcações abrangem tal *voxel*;
2. **União**: volume de segmentação que inclui todos os *voxels* das máscaras individuais;
3. **Sintético**: volume de segmentação produzido pelo método proposto mas com o ponto de inicialização sendo o centróide da máscara de segmentação gerada pelo médico.

Em todos os experimentos o desempenho do método foi avaliado quantitativamente utilizando duas métricas de acurácia, o *Jaccard Index* (JI) e o *Dice Similarity Coefficient* (DSC). A métrica de *Jaccard* é uma medida de similaridade que compara elementos de dois conjuntos para calcular e determinar quais elementos são compartilhados e quais são distintos. Embora seja fácil de interpretar, o JI é extremamente sensível a tamanhos de amostras pequenas. O *Dice Similarity Coefficient* é um índice de sobreposição espacial e uma métrica de validação de reprodutibilidade. Este índice tornou-se indiscutivelmente a ferramenta mais amplamente utilizada na validação de algoritmos de segmentação de imagem, mas é um conceito muito mais geral que pode ser aplicado a conjuntos de dados para uma variedade de aplicações. Ambas as métricas são calculadas de acordo com as equações:

$$JI = \frac{|P \cap R|}{|P \cup R|} \quad (3.7)$$

$$DSC = \frac{2|P \cap R|}{|P| + |R|} \quad (3.8)$$

Para as equações indicadas anteriormente, P equivale a máscara resultante do método proposto e R a máscara de referência. Os valores de DSC e do JI variam de 0, indicando que não há sobreposição volumétrica entre P e R , até 1, indicando completa sobreposição entre as duas máscaras. Diversos trabalhos propõem métodos de segmentação para imagens médicas e avaliam os mesmos utilizando as métricas de JI (ALI; IRTAZA; MAQSOOD, 2022; SINGADKAR et al., 2020) e DSC Jain, Indora e Atal (2021), Zhang et al. (2021).

3.3.1 Experimento 1

O tempo decorrido entre a realização do exame de TC e a divulgação do diagnóstico médico ao paciente é composto por, dentre outras atividades, o processo de segmentação 3D em si da lesão pulmonar. Como o fator **detecção precoce** é fundamental para o aumento da estimativa de vida do indivíduo acometido de câncer de pulmão, a diminuição do tempo de segmentação 3D da lesão na prática clínica, por muitas vezes realizada de forma manual, minuciosa e demorada, é de extrema importância, para que o diagnóstico seja fornecido o mais rápido possível. Dessa forma, métodos de segmentações automáticas devem ser comparáveis as segmentações manuais, não só quanto ao tempo mas também quanto a qualidade de segmentação, para que os mesmos possa ser absorvidos e de fato utilizados, contribuindo assim de forma considerável com a sociedade.


O procedimento compreendido no experimento 1, prover a comparação entre os resultados do método proposto para segmentação automática e os resultados das segmentações realizadas

por médicos especialistas, ambas para um mesmo nódulo. Assim como descrito previamente, o método proposto produz uma máscara binária 3D contendo o resultado de segmentação. Para que seja possível realizar a comparação entre conjuntos semelhantes, dado um determinado nódulo, máscaras binárias de mesmas dimensões foram geradas: uma máscara de referência para cada segmentação individual do médico e uma máscara para as referências *consensus* ou união.

Dado um nódulo não sólido do conjunto de dados selecionado, o resultado do método de segmentação proposto é gerado a partir do ponto de inicialização resultante da média dos centróides fornecidos pelos médicos, assim como detalhado anteriormente. Além disso, são extraídas as máscaras binárias individuais dos médicos e, por fim, são geradas as máscaras de referência *consensus* ou união, ambas calculadas a partir das máscaras de segmentação individual dos médicos, mas com diferentes critérios de inclusão aplicados aos *voxels*. As etapas para estruturação e procedimento deste experimento assim como um exemplo das imagens geradas são mostradas nas Figuras 35 e 36, respectivamente.

Isto posto, o objetivo deste experimento é determinar o desempenho de segmentação do método de segmentação proposto comparado às máscaras de referência *consensus*, união e a segmentação individual dos especialistas, mostrando que é possível integração de um método confiável, adequado e rápido à prática clínica.

Figura 35 – Infográfico experimento 1




Fonte: Elaborada pelo autor

3.3.2 Experimento 2

O processo de segmentação de nódulos não sólidos é um processo altamente complexo e, principalmente para segmentações manuais, um processo indefinido e exaustivo. Todas essas individualidades fazem com que, inclusive, radiologistas com vasta experiência discordem entre si e aconteça casos que um mesmo especialista segmente mais de uma vez o mesmo nódulo e resulte em segmentações diferentes. Dessa forma, para que um método de segmentação automático seja comparado à uma segmentação manual, se faz necessário diminuir a repercussão da variação entre as marcações dos médicos para um mesmo nódulo. Sendo assim, precisa-se que sejam usados, da máscara de segmentação resultante do método, somente os mesmos *slices* em que as máscaras de referência possuem marcações.

Figura 36 – Nódulo original, máscara de segmentação resultante do método proposto (contorno amarelo), máscara de referência *consensus* (contorno roxo) e máscaras individuais dos médicos 1 (contorno vermelho), 2 (contorno verde), 3 (contorno verde) e 4 (contorno laranja), para resultados de segmentação do experimento 1. a) Caso 48-2. b) Caso 179-0. c) Caso 394-5



Fonte: Elaborada pelo autor

Foi observado que as segmentações de referência apresentavam volumes que não tinham uma finalização contínua no eixo axial, ou seja, encerravam-se abruptamente, ao contrário das segmentações obtidas pelo método que aparentavam, ainda que de forma subjetiva, volumes com finalizações e contornos muito mais contínuos e suaves além de geometrias mais naturais. Devido a isto, estruturou-se este experimento e as Figuras 38 e 39 apresentam 5 *slices* para um mesmo nódulo com máscaras de referências *consensus* e união, respectivamente. Nas imagens, o retângulo vermelho indica quais *slices* do volume de segmentação resultante do método, serão comparados de acordo com os *slices* do volume de referência em que há segmentação.


O objetivo deste experimento é então semelhante ao objetivo do experimento 1 no que se refere a comparação do desempenho de segmentação do método proposto comparado às máscaras de referência, porém, estas últimas, com processo de geração diferente. O intuito deste experimento é comparar e avaliar a qualidade de segmentação do método somente sobre aqueles *slices* das máscaras de referências em que há *voxels* segmentados.

3.3.3 Experimento 3

O método proposto para segmentação automática de nódulos não sólidos requer que as coordenadas 3D de um ponto sejam fornecidas, para que assim toda a metodologia seja executada. A construção desta metodologia, principalmente através do estabelecimento dos dois conjuntos de raios, retira a dependência de que o ponto de inicialização necessite estar exatamente sobre o centro de massa da lesão. Dessa forma, o método tende a se tornar facilmente utilizável por radiologistas experientes ou não, reforçando a potencialidade do mesmo para integração às práticas clínicas.

O propósito deste experimento é determinar a reprodutibilidade do método proposto para *inputs* de diferentes especialistas, isto é, diferentes pontos de inicialização. Portanto, cada

Figura 37 – Nódulo original, máscara de segmentação resultante do método proposto (contorno amarelo), máscara de referência união (contorno rosa) e máscaras individuais dos médicos 1 (contorno vermelho), 2 (contorno verde), 3 (contorno verde) e 4 (contorno laranja), para resultados de segmentação do experimento 1. a) Caso 223-0. b) Caso 777-3. c) Caso 587-0




Fonte: Elaborada pelo autor

nódulo (Figura 40a) possui, uma quantidade de centróides semelhante à quantidade de anotações, além da coordenada da média dos centróides (Figura 40c). Para este experimento, todas estas coordenadas são utilizadas como *inputs* do método de segmentação (Figura 40d), gerando assim as devidas máscaras resultantes (Figura 40e). A comparação de todas as máscaras geradas com a referência sendo a resultante do método é realizada, mostrando que para diferentes interpretações, ou seja, para diferentes pontos de inicialização próximos ao centro do nódulo, são produzidos resultados de segmentação semelhantes. As etapas para estruturação deste experimento assim como um exemplo das imagens geradas são mostradas nas Figuras 40 e 41, respectivamente.


Desta maneira, o objetivo deste experimento é determinar que há uma região válida, próxima ao centro de massa da lesão em que os resultados de segmentação não variam para diferentes pontos de inicialização, ou seja, que o grau de discordância entre os médicos especialistas tende a ser menor caso o método de segmentação seja utilizado em oposição a segmentação manual.

Figura 38 – Sequência de 5 *slices* para o a) nódulo original, b) máscara de referência *consensus* e c) máscara de segmentação resultante do método proposto. Caso 402-4




Fonte: Elaborada pelo autor

Figura 39 – Sequência de 5 *slices* para o a) nódulo original, b) máscara de referência união e c) máscara de segmentação resultante do método proposto. Caso 339-0




Fonte: Elaborada pelo autor

Figura 40 – Infográfico experimento 3



Fonte: Elaborada pelo autor

Figura 41 – Nódulo original, máscara de segmentação resultante do método proposto (contorno amarelo) e máscaras de segmentação dos médicos 1 (contorno vermelho), 2 (contorno verde), 3 (contorno verde) e 4 (contorno laranja), para resultados de segmentação do experimento 3. a) Caso 223-0. b) Caso 298-0. c) Caso 686-4



Fonte: Elaborada pelo autor

4 RESULTADOS E DISCUSSÕES

Neste capítulo são apresentados e discutidos os resultados obtidos pelo método de segmentação automática proposto para segmentação dos nódulos não sólidos em exames de TC do tórax, aplicado ao banco de nódulos descrito anteriormente e oriundo do LIDC/IDRI. Os três experimentos abordados e descritos anteriormente são realizados com o intuito de avaliar o desempenho da abordagem proposta, tanto do ponto de vista de assertividade e acurácia geral, quanto de qualidade da segmentação final obtida, considerando-se a quantidade de nódulos segmentados. Desta forma, os resultados são divididos em duas partes: performance do método e qualidade de segmentação.

Os resultados da aplicação do método sobre os nódulos do conjunto de exames e nódulos descritos anteriormente, apresentaram um tempo médio de segmentação de 0,85 segundos e desvio padrão de 0,20. Ou seja, o método automático proposto requer um tempo computacional de menos de 1 segundo, tempo de segmentação este inferior à outras segmentações para nódulos não sólidos da literatura como Liu et al. (2015) com 5 segundos, Dong et al. (2020) com 16 segundos e consideravelmente menor que Charbonnier et al. (2018) que também apresenta uma metodologia baseada em raios, com 76 segundos para segmentação de uma lesão. Vale ressaltar que o método apresenta também um tempo de segmentação muito menor que as segmentações manuais além de diminuir a variabilidade entre os usuários sendo assim totalmente adequado à implementação na prática clínica. O sistema foi desenvolvido e executado em um *desktop* de sistema operacional Windows 10, processador Intel Core i7-9700KF de 3.60 Ghz, com 64 GB de memória RAM e placa de vídeo GeForce RTX 2060 SUPER. A linguagem predominante foi Python e suas bibliotecas externas de processamento de imagens e computação numérica.

4.1 Desempenho do Método de Segmentação

Com a finalidade de se estimar a amplitude e o aproveitamento geral do método automático de segmentação proposto, foi realizada a aplicação do mesmo sobre todos os nódulos do banco de dados estruturado na Seção 3.2. Para este cenário de teste, foram segmentados de forma satisfatória 105 nódulos, dos 118 iniciais, resultando em uma acurácia geral de segmentação de 88,98%, significando que em 11,01% dos nódulos, ou seja, somente em 13 nódulos, o método apresentou segmentações inadequadas. Este resultado de performance geral, corrobora que o método de segmentação automático de nódulos não sólidos proposto, apesar de todas as complexidades de limitação e determinação das extremidades desse tipo de lesão por humanos e também complexo para máquinas, se mostra eficaz e adequado para utilização na prática clínica e melhora do auxílio ao diagnóstico médico, além de realizar uma segmentação com um tempo médio de 0,85 segundos.

Para os 13 nódulos nos quais o método obteve resultado de segmentação inadequado, foram identificados padrões de resultados comuns onde a execução não obtém resultado de segmentação ou apresenta componentes únicos de volumes irrelevantes ou componentes fora da região do nódulo. Seguindo esta lógica, para tornar o proposto método de segmentação automático e preciso, estabeleceram-se critérios de filtros que justificam os comportamentos inadequados de segmentação, através das seguintes regras e ilustrados nas Figuras 42 e 43:

Critério 1: Método não obtém resultado de segmentação.

Para este cenário, o resultado final do método não apresenta nenhum componente segmentado.


Critério 2: *Método obtém como resultado de segmentação componentes únicos de volume irrelevantes, muitas vezes próximo à um voxel, ou múltiplos componentes dispersos também de volume insignificantes.*

Para este cenário, a segmentação resultante do método apresenta vários componentes conectados, na maioria das vezes espalhados na ROI, porém todos com volume menor que 10 *voxels*, ou seja, ruídos.

Critério 3: *Método obtém como resultado de segmentação componentes fora da região do nódulo*

Para este cenário, a segmentação resultante do método apresenta únicos ou múltiplos componentes conectados onde a distância euclidiana do centróide dos mesmos até o centro da ROI, é um valor maior que 5 *voxels*, estando assim todos os componentes fora de uma possível região do nódulo.


Figura 42 – *Slices* representando caso que justifica a elaboração do critério 2, onde o método obtém como resultado de segmentação componentes únicos de volume irrelevantes ou múltiplos componentes dispersos também de volume insignificantes. A primeira linha (itens a,b e c) revela as marcações do *consensus* e a segunda linha (itens d,e e f) as marcações do método de segmentação, ambas para uma mesma sequência de *slices* do caso 394-3



Fonte: Elaborada pelo autor

O método proposto proporciona então uma acurácia para a segmentação de todos os nódulos disponíveis no LIDC/IDRI, em que a maioria dos médicos especialistas concordam em ser uma lesão, e dentre os quais possuem textura média especificada como não sólido, de 88,98% juntamente com um baixo tempo de segmentação.

Figura 43 – Três *slices* representando um caso que justifica a elaboração do critério 3, onde o método obtém como resultado de segmentação componentes fora da região do nódulo. A primeira linha (itens a,b e c) revela as marcações do *consensus* e a segunda linha (itens d,e e f) as marcações do método de segmentação, ambas para uma mesma sequência de *slices* do caso 539-0



Fonte: Elaborada pelo autor

Na sequência, pretende-se analisar o mérito da qualidade das segmentações obtidas. Vale ressaltar que o fato das marcações realizadas pelos médicos especialistas não apresentarem um grau de concordância entre si, o desempenho do método proposto é prejudicado. À vista disso, se a variabilidade entre o método automático e um observador humano é semelhante à variabilidade entre dois observadores, o método automático é comparável a uma segmentação humana.

4.2 Qualidade da Segmentação

Como descrito anteriormente no Capítulo 2, a segmentação de nódulos não sólidos é um procedimento desafiador, sendo ela manual ou automático. Nódulos não sólidos não tem uma borda definida e são apresentados em um exame de TC com uma atenuação ligeiramente “turva” e densidades similares ao parênquima que o contorna, fazendo com que a detecção exata da borda do nódulo seja um procedimento muito subjetivo e complexo tanto para médicos especialistas, de forma manual ou semi automática através de sistemas CADs, como para máquinas e algoritmos computacionais.

Se dois ou mais especialistas são solicitados a realizar uma segmentação manual de um nódulo não sólido, os resultados provavelmente não serão idênticos, especialmente devido à dificuldade de se identificar as bordas desse tipo de nódulo. Até mesmo um único especialista, naturalmente não irá produzir resultados de segmentação semelhantes, caso repita várias vezes o processo para o mesmo nódulo, especialmente para nódulos sólidos. Além do nível de experiência do radiologista com esse tipo de lesão, o fator físico cansaço, fadiga também podem impactar diretamente na correta e específica delimitação do nódulo pelo usuário.

Tabela 3 – Resultados para as métricas de *Jaccard Index* e *Dice Coefficient* da comparação entre as máscaras binárias resultantes do método proposto de segmentação e as máscaras binárias de referências *consensus* e união.

<i>Jaccard Index (%)</i>		
	Referência <i>Consensus</i>	Referência União
Máximo	94,23	78,66
Mínimo	1,58	2,00
Média	41,65	43,73
<i>Dice Coefficient (%)</i>		
Máximo	97,00	88,10
Mínimo	3,10	4,40
Média	55,61	58,40

Fonte: Elaborada pelo autor

4.2.1 Experimento 1

O experimento 1 descrito anteriormente, que tem o objetivo de comparar o método proposto de segmentação automática frente a segmentação humana, foi realizado, corroborando que o ambas as segmentações são comparáveis. A Tabela 3 evidencia os resultados de valores máximo, mínimo e médio das métricas de *Jaccard Index* e *Dice Coefficient* para as comparações das máscaras binárias resultantes da segmentação do método com as devidas máscaras binárias de referências *consensus* e união, assim como a Tabela 4 revela as métricas de *JI* e *DSC* para a comparação direta do método com as segmentações individuais de cada médico. Os valores mínimo, máximo e média são extraídos a partir dos resultados das métricas de *JI* e *DSC* sobre os 118 nódulos do conjunto de dados.

Tabela 4 – Resultados para as métricas de *Jaccard Index* e *Dice Coefficient* da comparação entre as máscaras binárias resultantes do método proposto de segmentação e as máscaras binárias resultantes da segmentação dos médicos.

<i>Jaccard Index (%)</i>				
	Médico 1	Médico 2	Médico 3	Médico 4
Máximo	100,00	100,00	100,00	100,00
Mínimo	3,76	5,51	0,00	4,70
Média	69,56	70,20	69,69	72,72
<i>Dice Coefficient (%)</i>				
Máximo	100,00	100,00	100,00	100,00
Mínimo	7,30	10,40	0,00	9,00
Média	78,50	78,32	76,88	80,44

Fonte: Elaborada pelo autor

Para conseguirmos confirmar que o método de segmentação é comparável às segmentações humanas, determinar o grau de concordância entre os médicos especialistas pode ajudar a estimar a qualidade esperada do algoritmo de segmentação. No que diz respeito aos nódulos do conjunto de dados aqui selecionados, esse grau de concordância entre médicos pode ser comprovado de acordo com a Tabela 5.

A Tabela 5 valida a hipótese levantada anteriormente de que há uma variação entre os médicos especialistas quanto à definição e demarcação dos limites de um nódulo não sólido.

Tabela 5 – Resultados para as métricas de *Jaccard Index* e *Dice Coefficient* da comparação para as máscaras binárias resultantes de segmentação entre os médicos.

	<i>Jaccard Index (%)</i>	<i>Dice Coefficient (%)</i>
Máximo	67,87	70,43
Mínimo	46,64	47,79
Média	56,05	58,13

Fonte: Elaborada pelo autor

Ou seja, considerando a métrica de *JI*, os médicos concordam entre si quanto a marcação e delimitação de uma lesão não sólida, somente em 56,05%. Essa comprovação consolida na prática a complexidade e heterogeneidade do processo de segmentação desse tipo de nódulo para médicos experientes e altamente capacitados, o que naturalmente torna o procedimento complexo e heterogêneo também para máquinas.

É importante salientar que os valores para as métricas de *JI* e *DSC* são valores médios, significando que houveram nódulos que o método segmentou de forma satisfatória resultando em uma máscara mais semelhante à referência, mas por outro lado também houveram resultados ruins de segmentações pelo método.

Outro ponto que é válido destacar é que em alguns casos as marcações de referência variam muito entre si, o que justifica os baixos valores revelados na Tabela 5. Podemos observar alguns desses casos, nas imagens 44 e 45, percebendo que há uma alta variância entre os especialistas como discutido anteriormente, assim como situações em que um dos especialistas realiza uma marcação desconforme e que não se assemelha às marcações dos outros médicos para o mesmo nódulo.

4.2.2 Experimento 2


Além do alto grau de discordância de segmentação entre os médicos especialistas, se considerarmos somente os *slices* das máscaras de referências em que há marcações, ou seja, diminuindo o impacto da variação entre as marcações dos médicos para um mesmo nódulo, percebe-se que existe um aumento de desempenho do método. Isso significa que o método proposto segmenta regiões as quais não são marcadas pelos médicos, impossibilitando um melhor resultado de segmentação uma vez que não há máscara de referência para comparação.

Por meio da Tabela 6, podemos observar que, de fato, o método automático de segmentação apresenta um aumento de desempenho médio da métrica *Jaccard Index* de 9,74% quando comparado ao *consensus* como referência, de 7,42% para a referência sendo a união e ao compararmos através da métrica *Dice Coefficient*, observamos um aumento de aproximadamente 2,96% quando comparado ao *consensus* como referência e de 7,14% para a referência sendo a união.

Ainda para os resultados mostrados na Tabela 6, confirmamos que existem regiões que o método segmenta que não foram consideradas pelos médicos especialistas e, por consequência, não marcadas nas máscaras de referência. Isso também confirma a hipótese de que há uma sobresegmentação presente principalmente no eixo axial, ou seja, há uma parcela de região de nódulo segmentada pelo método que está sendo considerada como erro de segmentação, já que ao ser comparada com as máscaras de referência, as mesmas não possuem marcações para estas regiões.

Com o intuito de se avaliar e analisar essas regiões que o método proposto está segmen-

Figura 44 – Representação de casos onde há alta variância quanto as marcações dos médicos especialistas para um mesmo nódulo. Casos (a) 08-0, (b) 388-1, (c) 777-2, (d) 994-3



Fonte: Elaborada pelo autor


Tabela 6 – Resultados para as métricas de *Jaccard Index* e *Dice Coefficient* da comparação entre as máscaras de segmentação do método e as referências *consensus* e união somente para *slices* com marcação.

<i>Jaccard Index (%)</i>		
	Referência <i>Consensus</i>	Referência União
Máximo	94,23	85,49
Mínimo	5,97	4,54
Média	51,39	51,15
<i>Dice Coefficient (%)</i>		
Máximo	97,00	92,20
Mínimo	0,00	8,70
Média	58,57	65,54

Fonte: Elaborada pelo autor

tando, entretanto estão sendo consideradas como erro de segmentação, as Figuras 46, 47, 48 e 49 mostram o comportamento das mesmas no volume de segmentação do nódulo, destacando também as visualizações 3D. Podemos observar que estas regiões de sobresegmentação tornam os resultados do método volumes mais naturais e sem interrupções abruptas, ao contrário das segmentações de referência, muitas das vezes causada pela alta variação de concordância entre médicos. Outra observação que conseguimos comprovar é que os volumes resultantes do método aparentam, ainda que de forma subjetiva, formatos mais próximos a um objeto natural que

Figura 45 – Representação de casos que comprovam uma ou mais marcações desconforme com as demais. Casos (a) 128-2, (b) 240-0, (c) 298-0, (d) 539-0



Fonte: Elaborada pelo autor


evidencia uma finalização com contornos mais suaves e afunilada, ou seja, uma geometria mais autêntica do que se está sendo segmentado.

Certificando que este resultado de sobresegmentação obtido pelo método de segmentação é, na verdade, satisfatório, podemos ainda concluir que estas regiões de sobresegmentação apresentam características de densidade semelhante às marcações de nódulo realizadas pelos médicos. Essa semelhança aumenta a probabilidade destas regiões pertencerem às lesões em questão, também pelo fato de que por ser um processo abstrato e desgastante, a segmentação tridimensional realizada pelos médicos especialistas tende a não segmentar com muita perícia todos os *slices*, não havendo assim uma concordância com a realidade. Tal observação pode ser comprovada através das visualizações 2D dos *slices* mostradas nas Figuras 46 e 48.

4.2.3 Experimento 3


O experimento 3, descrito com mais detalhes na Seção 3.3.3, tem o propósito de **mostrar que a variabilidade de concordância entre os médicos especialistas é menor caso os mesmos utilizem o método de segmentação proposto, comparada à variabilidade quando os médicos segmentam o nódulo de forma manual**. Em outras palavras, o experimento 3 comprova a hipótese de que há uma região válida próxima ao centro do nódulo que para diferentes interpretações dos usuários, ou seja, diferentes pontos de inicialização caso contidos nesta região, resultam em volumes de segmentação similares, justificando a reprodutibilidade do método devido aos processos de geração dos grupos de raios que corrigem distorções na definição do centro do nódulo, situações comprovadas na **Figura 50**.

Figura 46 – Representações 2D da comparação por *slices* entre as segmentações da a) referência *consensus* e do b) método de segmentação proposto, ambas para uma mesma sequência de *slices* do caso 131-1



Fonte: Elaborada pelo autor

Figura 47 – Representações 3D da comparação dos volumes segmentados pelo (a) método segmentação proposto e (b) referência *consensus*. Caso 131-1




Fonte: Elaborada pelo autor

Finalizando as análises técnicas, o gráfico mostrado na **Figura 51**, revela os valores da métrica *Jaccard Index* para os 360 resultados de segmentações compostos por um resultado de segmentação para cada marcação dos 64 nódulos com 3 marcações e 42 nódulos com 4 marcações, resultantes a realização do experimento 3. É importante evidenciar que **dentre as 273 segmentações que obtiveram métricas de JI acima de 45%, 56% (153 segmentações) dessas, ou seja, 42,50% de todas as 360 segmentações, obtiveram JI igual a 100% significando um volume de segmentação completamente igual a referência.**


Com base no conjunto de resultados das diferentes análises e nas discussões apresentadas

Figura 48 – Representações 2D da comparação por *slices* entre as segmentações da a) referência *consensus* e do b) método de segmentação proposto, ambas para uma mesma sequência de *slices* do caso 498-1



Fonte: Elaborada pelo autor


Figura 49 – Representações 3D da comparação dos volumes segmentados pelo (a) método segmentação proposto e (b) referência *consensus*. Caso 498-1



Fonte: Elaborada pelo autor


neste Capítulo, algumas conclusões, contribuições e sugestões para trabalhos futuros podem ser evidenciadas.

Figura 50 – Nódulo original, máscara de segmentação resultante do método (contorno amarelo) e máscaras de segmentação dos médicos 1 (contorno vermelho), 2 (contorno verde), 3 (contorno verde) e 4 (contorno laranja), para resultados de segmentação do experimento 3. a) Caso 179-0. b) Caso 240-0. c) Caso 288-1. d) Caso 480-0



Fonte: Elaborada pelo autor

Figura 51 – Distribuição dos valores para a métrica de *Jaccard Index* resultantes do experimento 3 que tem o objetivo de determinar a reprodutibilidade do método proposto de segmentação



Fonte: Elaborada pelo autor

5 CONCLUSÃO, CONTRIBUIÇÕES E TRABALHOS FUTUROS

Nesta dissertação é proposta e avaliada uma estratégia baseada na geração de raios e manipulação de coordenadas polares para se definir o maior diâmetro de um nódulo não sólido e realização de segmentação automática tridimensional de nódulos pulmonares não sólidos a partir de imagens de tomografia computadorizada do tórax. A referida técnica se baseia na geração de dois grupos de raios, na aplicação da ponderação de energia baseada na média de densidade, para que após a execução do critério Média de Densidades Bidirecional Iterativa (MDBI), seja definido o maior diâmetro da lesão. Além dessas, completam as etapas do método de segmentação a geração da região de interesse, análise de histograma e crescimento de região, remoção de parede pulmonar, remoção de vasos anexos e reconstrução do nódulo.

A seleção do segmento de reta que representa o maior diâmetro da lesão, junto às demais etapas citadas, compõem o método de segmentação que foi aplicado sobre 118 nódulos extraídos de 86 exames contidos no banco de imagens LIDC/IDRI, onde pelo menos três médicos especialistas concordam que tal achado é uma lesão e o mesmo possuir textura média menor ou igual a 3, ou seja, nódulo não sólido.

Para análise e avaliação do método proposto, três experimentos foram estruturados para que fosse possível avaliar, de forma quantitativa, a performance do método de segmentação comparado às referências do padrão ouro de segmentação gerado pelos médicos especialistas. Duas métricas de acurácia foram utilizadas: *Jaccard Index* (JI) e *Dice Similarity Coefficient* (DSC). Dois dos três experimentos foram criados com o intuito de comparar os resultados do método de segmentação proposto com as máscaras de referência *consensus*, união e segmentação individual dos especialistas de forma geral e também considerando somente aqueles *slices* das máscaras de referência em que há *voxels* segmentados. Já o terceiro experimento teve o objetivo de determinar a reprodutibilidade do método proposto.

O método de segmentação aplicado aos 118 nódulos do *dataset* aqui considerado, segmentou de forma satisfatória 105 nódulos, apresentando assim uma acurácia geral de segmentação de 88,98%. Os nódulos para quais o método obteve resultado de segmentação inadequado, atendem a critérios justificados através das regras discutidas na seção 4.1. Outro ponto importante a se destacar é o tempo médio necessário para segmentação de uma lesão, igual a 0,85 segundos, sendo este consideravelmente menor que outras técnicas de segmentação discutidas neste trabalho, e totalmente adequado para implantação na prática clínica.

O mérito da qualidade de segmentação do método também foi avaliado e comprovado, após determinação do grau de concordância entre os médicos, que o método apresentado é comparável às segmentações humanas. Foi mostrado ainda que tridimensionalmente o método proposto apresenta formatos mais próximos a um objeto natural com finalização e contornos mais suaves e afunilados, ou seja, apresenta geometrias mais autênticas do que se está sendo segmentado. O experimento que determina a reprodutibilidade do método, resultou em 153, das 360 segmentações geradas, métricas de JI iguais a 100%, ou seja, um volume de segmentação completamente igual à referência.

A abordagem utilizada para alcançar os resultados de segmentação automática 3D de nódulos não sólidos configura a principal contribuição desta dissertação. Além disso, a implementação e validação do tratamento de ponderação de energia baseada na média das densidades, também chamado de Média de Densidades Bidirecional Iterativa (MDBI), configura uma outra contribuição desta dissertação. Este critério aplica uma sequência de operações recursivas a cada

raio individualmente com o objetivo de limitar a lesão através da detecção de possíveis pontos de bordas, e assim a sequência do método processa somente informações úteis do nódulo.

Os resultados obtidos neste trabalho trazem contribuições significativas à prática clínica, pelo fato de apresentar auxílio ao diagnóstico médico na forma de confiabilidade, acurácia, agilidade e produtividade para o profissional. A inserção de técnicas computacionais avançadas ao cotidiano médico traz benefícios no relacionamento médico paciente, sendo possível realizar análises cada vez menos invasivas além de possibilitar a realização de algumas tarefas com mais precisão, projetar cenários e fazer análises mais eficientes. Como contribuição e impacto social, este trabalho propicia o auxílio ao diagnóstico precoce do câncer de pulmão que é uma das principais estratégias para reduzir a mortalidade desse tipo de doença. Como consequência é possível iniciar um tratamento adequado e menos agressivo, além de se ter uma redução de custos para os serviços de saúde.

Diante do exposto, concluiu-se a eficiência da técnica proposta no processo de segmentação automática 3D de nódulos não sólidos, com um resultado tão eficiente quanto se deseje, comprovando que os objetivos propostos neste trabalho foram alcançados. Vale ressaltar que houveram casos em que o método não obteve resultado de segmentação satisfatórios, critérios estes justificados anteriormente, e que o ponto de inicialização da técnica proposta necessita que esteja em uma coordenada tal que faça parte da lesão, o mais próximo possível do centro da mesma.

O sucesso da segmentação automática de nódulos não sólidos, estimula o desenvolvimento de pesquisas que podem ser sugeridas como trabalhos futuros, como por exemplo:

- integração com detecção automática de nódulos;
- avaliação de algoritmos de pré-processamentos e filtragem que possam resultar em uma imagem mais homogênea e que favoreça um maior destaque das bordas do nódulo;
- geração de raios tridimensionais.

REFERÊNCIAS

- ALI, Z.; IRTAZA, A.; MAQSOOD, M. An efficient U-Net framework for lung nodule detection using densely connected dilated convolutions. **JOURNAL OF SUPERCOMPUTING**, 78, n. 2, p. 1602–1623, FEB 2022. ISSN 0920-8542.
- ALMEIDA, T. M. D.; CORTEZ, P. C.; CAVALCANTE, T. D. S. Three-dimensional Radial Active Contour Model: A 3-D to 1-D Image Segmentation Technique. **IEEE LATIN AMERICA TRANSACTIONS**, 15, n. 2, p. 365–373, FEB 2017. ISSN 1548-0992.
- ALMEIDA, T. M. de. **MÉTODO DE CONTORNOS ATIVOS RADIAIS 3D: UMA NOVA ABORDAGEM PARA SEGMENTAÇÃO DE VOLUMES**. Dissertação (Tese) — Universidade Federal do Ceará (UFC), <https://repositorio.ufc.br/handle/riufc/42041>, Janeiro 2019.
- ANDREARCZYK, V. et al. Automatic segmentation of head and neck tumors and nodal metastases in pet-ct scans. In: PMLR. **Medical Imaging with Deep Learning**. [S.l.], 2020. p. 33–43.
- ANGAYARKANNI, S. P. Hybrid convolution neural network in classification of cancer in histopathology images. **Journal of Digital Imaging**, Springer, p. 1–10, 2022.
- ARMATO, S. et al. The lung image database consortium (lidc) and image database resource initiative (idri): A completed reference database of lung nodules on ct scans. **Medical Physics**, v. 38, p. 915–931, 01 2011.
- AVENDI, M.; KHERADVAR, A.; JAFARKHANI, H. Fully automatic segmentation of heart chambers in cardiac mri using deep learning. **Journal of Cardiovascular Magnetic Resonance**, BioMed Central, v. 18, n. 1, p. 1–3, 2016.
- BANON, G. J. F.; BARRERA, J. **Bases da morfologia matemática para a análise de imagens binárias**. [S.l.]: UFPE-DI, 1994.
- BEZDEK, J. et al. **FUZZY MODELS AND ALGORITHMS FOR PATTERN RECOGNITION AND IMAGE PROCESSING**. 1. ed. [S.l.]: Springer Science+Business Media, 2005. ISBN 0792385217.
- BRAY, F. et al. Global cancer statistics 2018: Globocan estimates of incidence and mortality worldwide for 36 cancers in 185 countries. **CA: A Cancer Journal for Clinicians**, v. 68, n. 6, p. 394–424, 2018. Disponível em: <<https://acsjournals.onlinelibrary.wiley.com/doi/abs/10.3322/caac.21492>>.
- CADASTRO NACIONAL DE ESTABELECIMENTOS DE SAUDE. **CNESNet/DataSus**. 2022. Disponível em: <https://www.http://cnes2.datasus.gov.br/Mod_Ind_Equipamento.asp?VEstado=00>. Acesso em: 30 jan. 2022.
- CAVALCANTE, T. da S. **Método de superfícies ativas usando local binary patterns (LBP) aplicado na segmentação de lobos pulmonares em imagens de tomografia computadorizada do tórax**. Tese (Tese) — Universidade Federal do Ceará (UFC), <http://www.repositorio.ufc.br/handle/riufc/19549>, Janeiro 2016.

CHAN, R.; KARL, W.; LEES, R. A new model-based technique for enhanced small-vessel measurements in x-ray cine-angiograms. **IEEE Transactions on Medical Imaging**, v. 19, n. 3, p. 243–255, 2000.

CHARBONNIER, J. P. et al. Automatic segmentation of the solid core and enclosed vessels in subsolid pulmonary nodules. **Scientific Reports**, Springer US, v. 8, n. 1, p. 1–11, 2018. ISSN 20452322. Disponível em: <<http://dx.doi.org/10.1038/s41598-017-19101-3>>.

CHEN, H. et al. Volumetric segmentation of ground glass nodule based on 3d attentional cascaded residual u-net and conditional radom field. **Medical physics**, Wiley Online Library, 2021.

CHIU, T.-W.; TSAI, Y.-L.; SU, S.-F. Automatic detect lung node with deep learning in segmentation and imbalance data labeling. **Scientific Reports**, Nature Publishing Group, v. 11, n. 1, p. 1–10, 2021.

CHOW, C.; KANEKO, T. Automatic boundary detection of the left ventricle from cineangiograms. **Computers and Biomedical Research**, v. 5, n. 4, p. 388–410, 1972. ISSN 0010-4809. Disponível em: <<https://www.sciencedirect.com/science/article/pii/0010480972900705>>.

CHUNG, K. et al. Visual discrimination of screen-detected persistent from transient subsolid nodules: An observer study. **PLoS ONE**, v. 13, n. 2, p. 1–12, 2018. ISSN 19326203.

CLUNIE, D. A. DICOM Format and Protocol Standardization—A Core Requirement for Digital Pathology Success. **Toxicologic Pathology**, v. 49, n. 4, p. 738–749, 2021. ISSN 15331601.

DE ALEXANDRIA, A. R. et al. psnakes: A new radial active contour model and its application in the segmentation of the left ventricle from echocardiographic images. **Computer Methods and Programs in Biomedicine**, v. 116, n. 3, p. 260–273, 2014. ISSN 0169-2607. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0169260714002077>>.

DELON, J. et al. A nonparametric approach for histogram segmentation. **IEEE Transactions on Image Processing**, v. 16, n. 1, p. 253–261, 2007.

DONG, Y. et al. An improved supervoxel 3D region growing method based on PET/CT multimodal data for segmentation and reconstruction of GGNs. **Multimedia Tools and Applications**, Multimedia Tools and Applications, v. 79, n. 3-4, p. 2309–2338, 2020. ISSN 15737721.

FAJAR, A. et al. Reconstructing and resizing 3D images from DICOM files. **Journal of King Saud University - Computer and Information Sciences**, The Authors, n. xxxx, 2021. ISSN 22131248. Disponível em: <<https://doi.org/10.1016/j.jksuci.2020.12.004>>.

FARAG, A. A. et al. A novel approach for lung nodules segmentation in chest ct using level sets. **IEEE Transactions on Image Processing**, IEEE, v. 22, n. 12, p. 5202–5213, 2013.

FEDOROV, A. et al. Dicom re-encoding of volumetrically annotated lung imaging database consortium (lidc) nodules. **Medical physics**, Wiley Online Library, v. 47, n. 11, p. 5953–5965, 2020.

GEVENOIS, P. A. et al. Comparison of computed density and macroscopic morphometry in pulmonary emphysema. **American Journal of Respiratory and Critical Care Medicine**, v. 152, n. 2, p. 653–657, 1995. ISSN 1073449X.

GONZALEZ, R. C.; WOODS, R. E. **Digital image processing (4nd ed.)**. [S.l.: s.n.], 2018. v. 55. 219 p. ISBN 978-0-13-335672-4.

GOUTSIAS, J.; VINCENT, L.; BLOOMBERG, D. S. **Mathematical morphology and its applications to image and signal processing**. [S.l.]: Springer Science & Business Media, 2006. v. 18.

HANCOCK, M. C.; MAGNAN, J. F. Lung nodule malignancy classification using only radiologist-quantified image features as inputs to statistical learning algorithms: probing the Lung Image Database Consortium dataset with two statistical learning methods. **Journal of Medical Imaging**, SPIE, v. 3, n. 4, p. 1 – 15, 2016. Disponível em: <<https://doi.org/10.1117/1.JMI.3.4.044504>>.

HANSELL, D. M. et al. Fleischner Society: Glossary of terms for thoracic imaging. **Radiology**, v. 246, n. 3, p. 697–722, 2008. ISSN 00338419.

HOJJATOLESLAMI, S.; KITTLER, J. Region growing: a new approach. **IEEE Transactions on Image Processing**, v. 7, n. 7, p. 1079–1084, 1998.

HOLBROOK, M. D. et al. Detection of lung nodules in micro-ct imaging using deep learning. **Tomography**, Multidisciplinary Digital Publishing Institute, v. 7, n. 3, p. 358–372, 2021.

HOOP, B. de et al. Pulmonary Ground-Glass Nodules : Increase in Mass as an Purpose : Methods : Results :. **Radiology**, v. 255, n. 1, p. 199–206, 2010.

HOUNSFIELD, G. N. Computerized transverse axial scanning (tomography): Part I. Description of system. **British Journal of Radiolog**, v. 46, p. 1016–1022, 1973. ISSN 03603016.

INCA. **Estimativa 2020 : incidência de câncer no Brasil**. Rio de Janeiro, RJ: [s.n.], 2019. 122 p. ISBN 9788573183887.

INTERNATIONAL AGENCY FOR RESEARCH ON CANCER. **IARC/WHO**. 2022. Disponível em: <https://www.iarc.who.int/cards_page/about-iarc/>. Acesso em: 30 jan. 2022.

JAIN, S.; INDORA, S.; ATAL, D. K. Lung nodule segmentation using Salp Shuffled Shepherd Optimization Algorithm-based Generative Adversarial Network. **COMPUTERS IN BIOLOGY AND MEDICINE**, 137, OCT 2021. ISSN 0010-4825.

JU, Z. et al. Automatic segmentation of pelvic organs-at-risk using a fusion network model based on limited training samples. **Acta Oncologica**, Taylor & Francis, v. 59, n. 8, p. 933–939, 2020.

JUNG, J.; HONG, H.; GOO, J. M. Ground-glass nodule segmentation in chest CT images using asymmetric multi-phase deformable model and pulmonary vessel removal. **Computers in Biology and Medicine**, Elsevier Ltd, v. 92, n. November 2017, p. 128–138, 2018. ISSN 18790534. Disponível em: <<https://doi.org/10.1016/j.combiomed.2017.11.013>>.

KIM, Y. J. et al. Evaluation of semi-automatic segmentation methods for persistent ground glass nodules on thin-section CT scans. **Healthcare Informatics Research**, v. 22, n. 4, p. 305–315, 2016. ISSN 2093369X.

KOCKELKORN, T. **Interactive texture analysis in chest {CT} Scans**. [s.n.], 2017. ISBN 9789039367063. Disponível em: <<https://dspace.library.uu.nl/handle/1874/343111>>.

KOH, J. et al. Deep learning for the detection of breast cancers on chest computed tomography. **Clinical Breast Cancer**, Elsevier, v. 22, n. 1, p. 26–31, 2022.

KUBOTA, T. et al. Segmentation of pulmonary nodules of various densities with morphological approaches and convexity models. **Medical Image Analysis**, Elsevier, v. 15, n. 1, p. 133–154, 2011.

LASSEN, B. et al. Automatic segmentation of the pulmonary lobes from chest ct scans based on fissures, vessels, and bronchi. **IEEE transactions on medical imaging**, IEEE, v. 32, n. 2, p. 210–222, 2012.

LASSEN, B. C. et al. Robust semi-automatic segmentation of pulmonary subsolid nodules in chest computed tomography scans. **Physics in Medicine and Biology**, IOP Publishing, v. 60, n. 3, p. 1307–1323, 2015. ISSN 13616560.

LEE, S. U.; Yoon Chung, S.; PARK, R. H. A comparative performance study of several global thresholding techniques for segmentation. **Computer Vision, Graphics, and Image Processing**, v. 52, n. 2, p. 171–190, 1990. ISSN 0734-189X. Disponível em: <<https://www.sciencedirect.com/science/article/pii/0734189X9090053X>>.

LEONARDI, R. et al. Fully automatic segmentation of sinonasal cavity and pharyngeal airway based on convolutional neural networks. **American Journal of Orthodontics and Dentofacial Orthopedics**, Elsevier, v. 159, n. 6, p. 824–835, 2021.

LI, B. et al. Segmentation of ground glass opacity pulmonary nodules using an integrated active contour model with wavelet energy-based adaptive local energy and posterior probability-based speed function. **Materials Express**, v. 6, n. 4, p. 317–327, 2016. ISSN 21585857.

LIANG, Q. et al. A multiscale dynamic programming procedure for boundary detection in ultrasonic artery images. **IEEE Transactions on Medical Imaging**, v. 19, n. 2, p. 127–142, 2000.

LIAO, P. sung; CHEN, T. sheng; CHUNG, P. choo. A fast algorithm for multilevel thresholding. **Journal of Information Science and Engineering**, v. 17, p. 713–727, 2001.

LIU, H. et al. Research on a pulmonary nodule segmentation method combining fast self-adaptive FCM and classification. **Computational and Mathematical Methods in Medicine**, Hindawi Publishing Corporation, v. 2015, 2015. ISSN 17486718.

Lopez Torres, E. et al. Large scale validation of the M5L lung CAD on heterogeneous CT datasets. **Medical Physics**, v. 42, n. 4, p. 1477–1489, 2015. ISSN 00942405. Disponível em: <<http://dx.doi.org/10.1118/1.4907970>>.

MACCHIA, M. L. et al. Systematic evaluation of three different commercial software solutions for automatic segmentation for adaptive therapy in head-and-neck, prostate and pleural cancer. **Radiation Oncology**, BioMed Central, v. 7, n. 1, p. 1–16, 2012.

MAHMOOD, T. et al. An automatic detection and localization of mammographic microcalcifications roi with multi-scale features using the radiomics analysis approach. **Cancers**, Multidisciplinary Digital Publishing Institute, v. 13, n. 23, p. 5916, 2021.

MANICKAVASAGAM, R.; SELVAN, S.; SELVAN, M. Cad system for lung nodule detection using deep learning with cnn. **Medical & Biological Engineering & Computing**, Springer, v. 60, n. 1, p. 221–228, 2022.

MANZOOR, K. et al. A lightweight approach for skin lesion detection through optimal features fusion. **CMC-COMPUTERS MATERIALS & CONTINUA**, TECH SCIENCE PRESS 871 CORONADO CENTER DR, SUTE 200, HENDERSON, NV 89052 USA, v. 70, n. 1, p. 1617–1630, 2022.

MCANDREW, A. An introduction to digital image processing with matlab notes for scm2511 image processing 1. **School of Computer Science and Mathematics, Victoria University of Technology**, p. 1–264, 2004.

MCWILLIAMS, A. et al. Probability of cancer in pulmonary nodules detected on first screening CT. **New England Journal of Medicine**, v. 369, n. 10, p. 910–919, 2013. ISSN 15334406.

MEN, K.; DAI, J.; LI, Y. Automatic segmentation of the clinical target volume and organs at risk in the planning ct for rectal cancer using deep dilated convolutional neural networks. **Medical physics**, Wiley Online Library, v. 44, n. 12, p. 6377–6389, 2017.

MENG, Q. et al. Automatic segmentation of airway tree based on local intensity filter and machine learning technique in 3d chest ct volume. **International journal of computer assisted radiology and surgery**, Springer, v. 12, n. 2, p. 245–261, 2017.

MUKHOPADHYAY, S. A segmentation framework of pulmonary nodules in lung ct images. **Journal of digital imaging**, Springer, v. 29, n. 1, p. 86–103, 2016.

MUSALLAM, A. S.; SHERIF, A. S.; HUSSEIN, M. K. A new convolutional neural network architecture for automatic detection of brain tumors in magnetic resonance imaging images. **IEEE Access**, IEEE, 2022.

NAIR, V. S. Management of lung nodules detected by volume CT scanning. **The New England journal of medicine**, v. 362, n. 8, p. 2221–2229, 2010. ISSN 15334406.

ORGANIZACAO PAN-AMERICANA DA SAÚDE. **OPAS/OMS**. 2022. Disponível em: <<https://www.paho.org/pt>>. Acesso em: 30 jan. 2022.

OTSU, N. A threshold selection method from gray-level histograms. **IEEE Transactions on Systems, Man, and Cybernetics**, v. 9, n. 1, p. 62–66, 1979.

PARKER, J. R. **Algorithms for Image Processing and Computer Vision**. 2nd. ed. [S.l.]: Wiley Publishing, 2010. ISBN 0470643854.

PERONI, M. et al. Automatic segmentation and online virtualct in head-and-neck adaptive radiation therapy. **International Journal of Radiation Oncology* Biology* Physics**, Elsevier, v. 84, n. 3, p. e427–e433, 2012.

RAHMAN, H. et al. Performance evaluation of region-growing based segmentation algorithms for segmenting the aorta. **Jurnal Teknologi**, v. 78, n. 4-3, 2016.

RANGAYYAN, M. R. N. R. M. **Biomedical Image Analysis**. 1. ed. [S.l.]: University of Calgary - CRC Press, 2004. ISBN 978-0849396953.

RICKE, A. D.; POVINELLI, R. J.; JOHNSON, M. T. Automatic segmentation of heart sound signals using hidden markov models. In: IEEE. **Computers in Cardiology**, 2005. [S.l.], 2005. p. 953–956.

RIKXOORT, E. M. V. et al. Automatic segmentation of pulmonary lobes robust against incomplete fissures. **IEEE transactions on medical imaging**, IEEE, v. 29, n. 6, p. 1286–1296, 2010.

SAHOO, P.; SOLTANI, S.; WONG, A. A survey of thresholding techniques. **Computer Vision, Graphics, and Image Processing**, v. 41, n. 2, p. 233–260, 1988. ISSN 0734-189X. Disponível em: <<https://www.sciencedirect.com/science/article/pii/0734189X88900229>>.

SAUVOLA, J.; PIETIKÄINEN, M. Adaptive document image binarization. **Pattern Recognition**, v. 33, n. 2, p. 225–236, 2000. ISSN 0031-3203. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0031320399000552>>.

SAVITHA, G.; JIDESH, P. A fully-automated system for identification and classification of subsolid nodules in lung computed tomographic scans. **Biomedical Signal Processing and Control**, Elsevier Ltd, v. 53, p. 101586, 2019. ISSN 17468108. Disponível em: <<https://doi.org/10.1016/j.bspc.2019.101586>>.

SCHOLTEN, E. T. et al. Detection and quantification of the solid component in pulmonary subsolid nodules by semiautomatic segmentation. **European Radiology**, v. 25, n. 2, p. 488–496, 2015. ISSN 14321084.

SHAKIBAPOUR, E. et al. An unsupervised metaheuristic search approach for segmentation and volume measurement of pulmonary nodules in lung ct scans. **Expert Systems with Applications**, Elsevier, v. 119, p. 415–428, 2019.

Siemens Medical Solutions. Computed Tomography Its History and Technology Innovations For People. **CT Basics**, 2013. Disponível em: <http://globaldxi.com/featureddocs/CT_History_and_Technology.pdf>.

SILVA FILHO, V. E. R. da. **Uma nova abordagem para a segmentação pulmonar com reinclusão de nódulos**. Dissertação (Dissertação) — Universidade Federal do Ceará (UFC), <https://repositorio.ufc.br/handle/riufc/36782>, Janeiro 2018.

SINGADKAR, G. et al. Deep Deconvolutional Residual Network Based Automatic Lung Nodule Segmentation. **JOURNAL OF DIGITAL IMAGING**, 33, n. 3, p. 678–684, JUN 2020. ISSN 0897-1889.

SOCIETY, A. C. **American Cancer Society. Cancer Facts & Figures 2020**. 2020. 1–52 p. Disponível em: <<http://www.cancer.org/acs/groups/content/@nho/documents/document/caff2007pwsecuredpdf.pdf>>.

SOILLE, P. **Morphological Image Analysis**. [S.l.: s.n.], 1999. ISBN 9783642076961.

SOLOMON, C.; BRECKON, T. **Fundamentos de Processamento Digital de Imagens**. 1. ed. [S.l.]: Grupo Editorial Nacional - LTC, 2013. ISBN 978-85-216-2347-2.

SONKA, M.; HLAVAC, V.; BOYLE, R. Image processing, anlysis and machine vision. p. 112–191, 1993.

SUJI, R. J. et al. Optical flow methods for lung nodule segmentation on lidc-idri images. **Journal of Digital Imaging**, Springer, v. 33, n. 5, p. 1306–1324, 2020.

SUN, L. et al. Attention-embedded complementary-stream cnn for false positive reduction in pulmonary nodule detection. **Computers in Biology and Medicine**, Elsevier, v. 133, p. 104357, 2021.

THAN, J. C. et al. Lung disease stratification using amalgamation of Riesz and Gabor transforms in machine learning framework. **Computers in Biology and Medicine**, Elsevier Ltd, v. 89, n. August, p. 197–211, 2017. ISSN 18790534. Disponível em: <<http://dx.doi.org/10.1016/j.compbiomed.2017.08.014>>.

TSOU, C. H. et al. Anatomy packing with hierarchical segments: An algorithm for segmentation of pulmonary nodules in CT images. **BioMedical Engineering Online**, BioMed Central, v. 14, n. 1, p. 1–17, 2015. ISSN 1475925X.

WANG, S. et al. A multi-view deep convolutional neural networks for lung nodule segmentation. In: IEEE. **2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)**. [S.l.], 2017. p. 1752–1755.

WASHINGTON, Y. et al. **Computer Vision Algorithms in Image Algebra**. [S.l.: s.n.], 2001. 425 p. ISBN 0849300754.

WILD, C. P.; WEIDERPASS, E.; STEWART, B. W. **World Cancer Report: Cancer Research for Cancer Prevention**. Lyon, France: [s.n.], 2020. v. 199. 512 p. ISSN 00457825. ISBN 9789283204237. Disponível em: <<http://publications.iarc.fr/586>>.

WILSON, J. N.; RITTER, G. X. **Handbook of computer vision algorithms in image algebra**. [S.l.]: CRC press, 2000.

WOOD, D. E. The importance of lung cancer screening with low-dose computed tomography for medicare beneficiaries. **JAMA internal medicine**, American Medical Association, v. 174, n. 12, p. 2016–2018, 2014.

WU, W. et al. Segmentation of pulmonary nodules in CT images based on 3D-UNET combined with three-dimensional conditional random field optimization. **Medical Physics**, 2020. ISSN 00942405.

YAGUCHI, A. et al. Semi-automated segmentation of solid and GGO nodules in lung CT images using vessel-likelihood derived from local foreground structure. **Medical Imaging 2015: Computer-Aided Diagnosis**, v. 9414, n. March 2015, p. 94142S, 2015. ISSN 16057422.

YIN, P.-Y.; CHEN, L.-H. A fast iterative scheme for multilevel thresholding methods. **Signal Processing**, v. 60, n. 3, p. 305–313, 1997. ISSN 0165-1684. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0165168497000807>>.

YOUNG, R. P.; HOPKINS, R. J. CT screening for lung cancer. **Thorax**, v. 67, n. 7, p. 650–651, 2012. ISSN 14683296.

YUAN, H. et al. Pulmonary nodule detection using 3-d residual u-net oriented context-guided attention and multi-branch classification network. **IEEE Access**, IEEE, v. 10, p. 82–98, 2021.

ZAHARA, E.; FAN, S.-K. S.; TSAI, D.-M. Optimal multi-thresholding using a hybrid optimization approach. **Pattern Recognition Letters**, v. 26, n. 8, p. 1082–1095, 2005. ISSN 0167-8655. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0167865504003101>>.

ZHANG, S. et al. Segmentation of small ground glass opacity pulmonary nodules based on Markov random field energy and Bayesian probability difference. **BioMedical Engineering Online**, BioMed Central, v. 19, n. 1, p. 1–20, 2020. ISSN 1475925X. Disponível em: <<https://doi.org/10.1186/s12938-020-00793-0>>.

ZHANG, X. et al. Automatic detection and segmentation of lung nodules in different locations from CT images based on adaptive alpha-hull algorithm and DenseNet convolutional network. **INTERNATIONAL JOURNAL OF IMAGING SYSTEMS AND TECHNOLOGY**, 31, n. 4, p. 1882–1893, DEC 2021. ISSN 0899-9457.

ZHENG, Y. et al. Four-chamber heart modeling and automatic segmentation for 3-d cardiac ct volumes using marginal space learning and steerable features. **IEEE transactions on medical imaging**, IEEE, v. 27, n. 11, p. 1668–1681, 2008.

ZHOU, X. et al. Automatic segmentation and recognition of anatomical lung structures from high-resolution chest ct images. **Computerized Medical Imaging and Graphics**, Elsevier, v. 30, n. 5, p. 299–313, 2006.