



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE TELEINFORMÁTICA
DOUTORADO EM ENGENHARIA DE TELEINFORMÁTICA

ELIZÂNGELA DE SOUZA REBOUÇAS

**UMA ABORDAGEM POR *LEVEL SET* USANDO ESTIMAÇÃO NÃO PARAMÉTRICA
COM BASE NA JANELA DE PARZEN PARA SEGMENTAÇÃO AUTOMÁTICA DE
REGIÕES DE INTERESSE EM IMAGENS MÉDICAS**

FORTALEZA

2022

ELIZÂNGELA DE SOUZA REBOUÇAS

UMA ABORDAGEM POR *LEVEL SET* USANDO ESTIMAÇÃO NÃO PARAMÉTRICA
COM BASE NA JANELA DE PARZEN PARA SEGMENTAÇÃO AUTOMÁTICA DE
REGIÕES DE INTERESSE EM IMAGENS MÉDICAS

Tese apresentada ao Curso de Doutorado em Engenharia de Teleinformática do Programa de Pós-Graduação em Engenharia de Teleinformática do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial a obtenção do título de doutor em Engenharia de Teleinformática. Área de Concentração: Sinais e Sistemas

Orientadora: Prof^a. Dr^a. Fátima N. Sombra de Medeiros

Coorientador: Prof. Dr. Regis Cristiano Pinheiro Marques

FORTALEZA

2022

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Sistema de Bibliotecas

Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

R24a Rebouças, Elizângela de Souza.

Uma abordagem por level set usando estimação não paramétrica com base na janela de parzen para segmentação automática de regiões de interesse em imagens médicas / Elizângela de Souza Rebouças. – 2022.

78 f. : il. color.

Tese (doutorado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia de Teleinformática, Fortaleza, 2022.

Orientação: Profa. Dra. Fátima N. Sombra de Medeiros.

Coorientação: Prof. Dr. Regis Cristiano Pinheiro Marques.

1. Auxílio ao diagnóstico médico. 2. Contornos ativos. 3. Imagens médicas. 4. Segmentação de imagens. I. Título.

CDD 621.38

ELIZÂNGELA DE SOUZA REBOUÇAS

UMA ABORDAGEM POR *LEVEL SET* USANDO ESTIMAÇÃO NÃO PARAMÉTRICA
COM BASE NA JANELA DE PARZEN PARA SEGMENTAÇÃO AUTOMÁTICA DE
REGIÕES DE INTERESSE EM IMAGENS MÉDICAS

Tese apresentada ao Curso de Doutorado
em Engenharia de Teleinformática do
Programa de Pós-Graduação em Engenharia
de Teleinformática do Centro de Tecnologia
da Universidade Federal do Ceará, como
requisito parcial a obtenção do título de
doutor em Engenharia de Teleinformática.
Área de Concentração: Sinais e Sistemas

Aprovada em: 28 de julho de 2022

BANCA EXAMINADORA

Prof^a. Dr^a. Fátima N. Sombra de Medeiros (Orientadora)
Universidade Federal do Ceará (UFC)

Prof. Dr. Regis Cristiano Pinheiro Marques (Coorientador)
Instituto Federal do Ceará (IFCE)

Prof. Dr. Danielo Gonçalves Gomes
Universidade Federal do Ceará (UFC)

Prof. Dr. Abraão David Costa do Nascimento
Universidade Federal de Pernambuco (UFPE)

Prof^a. Dr^a Deborah Maria Vieira Magalhães
Universidade Federal do Piauí (UFPI)

Prof. Dr. Rodrigo de Melo Souza Veras
Universidade Federal do Piauí (UFPI)

Dedico este trabalho à minha família.

AGRADECIMENTOS

Agradeço primeiramente a Deus pela oportunidade de viver.

Aos meus pais, Terezinha e João Eudes, pela a oportunidade de estudar, pelo carinho incondicional e por sempre estarem ao meu lado.

Ao meu querido e amado esposo, Pedro Pedrosa, por sempre estar ao meu lado, me apoiando, me incentivando e me ajudando. Os dias e noites de estudo e trabalho com sua presença e apoio fizeram toda a diferença nesta caminhada.

À Profa. Dra. Fátima N. S. de Medeiros por sua orientação, respeito, atenção, dedicação e por todo o aprendizado que recebi durante este doutorado e a todos os membros da banca examinadora pelas considerações. Agradeço também ao Prof. Dr. Regis Cristiano Pinheiro Marques (IFCE) por sua coorientação e por todo o aprendizado que recebi desde o curso de mestrado.

À Universidade Federal do Ceará e a todo o corpo docente do Programa de Pós-Graduação em Engenharia de Teleinformática pelos bons ensinamentos que recebi.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior pelo apoio financeiro.

A todos que colaboraram de forma direta e indireta na elaboração deste trabalho.

“If you can dream it, you can do it”

(Walt Disney)

RESUMO

Esta tese tem como objetivo geral propor uma abordagem de *level set* usando uma estimação não paramétrica com base na janela de parzen para segmentação automática de regiões de interesse, visando o auxílio ao diagnóstico médico, chamada *FLog Parzen Level Set* (FPLS). O método FPLS é uma combinação do método *level set* utilizando uma abordagem de estimação não paramétrica baseada na janela de parzen e clusterização com Floor of Log para segmentação da região de interesse em imagens médicas. Nesta tese, a interseção do Floor of Log (FLog) com métodos de Processamento Digital de Imagens é responsável pela inicialização do ponto de semente na região de interesse, com o objetivo de determinar o *level set* zero. Essa combinação confere ao sistema maior robustez em determinar o *level set* zero que aumentará a eficiência na segmentação da região de interesse no menor tempo possível. Uma vez que a inicialização é mais estável, o crescimento da região e o refinamento com estimativas probabilísticas, usando a janela de parzen dentro do *level set*, produzem um resultado mais preciso. O método proposto foi aplicado e avaliado junto a outros da literatura em três aplicações: segmentação de regiões com Acidente Vascular Cerebral (AVC) em imagens de Tomografia do crânio, segmentação dos pulmões em imagens de Tomografia do tórax e segmentação de lesões de pele em imagens digitais. Os resultados apresentados demonstram a eficiência do FPLS em sistemas que auxiliam no diagnóstico médico. A velocidade do método proposto na segmentação e processamento de informações para diagnóstico médico é promissora, apresentando resultados eficientes e confiáveis, pois atinge resultados comparáveis e, muitas vezes, superiores aos outros métodos com baixo custo computacional. Portanto, considerando a análise geral dos resultados obtidos pela abordagem proposta, pode-se concluir que o FPLS é útil na segmentação de regiões de interesse. O método mostrou-se promissor na análise de imagens de pacientes sadios e também na análise de imagens que apresentam regiões com doença e com anomalias. Sendo assim, o FPLS pode ser integrado em sistemas de auxílio ao diagnóstico médico, seja para a finalidade de diagnóstico ou para o acompanhamento de doenças ao longo do tratamento, de forma mais direcionada, para a análise de AVC em imagens de Tomografia do crânio, de pulmões em imagens de Tomografia do tórax e de lesões de pele em imagens digitais.

Palavras-chave: Auxílio ao diagnóstico médico. Contornos ativos. Imagens médicas. Segmentação de imagens.

ABSTRACT

This thesis proposes a level set approach using a nonparametric estimation based on the parzen window to automatically segment regions of interest in medical images to aid medical diagnosis called the FLog Parzen Level Set (FPLS). The FPLS method combines the level set method using a nonparametric estimation approach based on parzen window and clustering with Floor of Log to segment the region of interest in medical images. In this thesis, the Floor of Log (FLog) intersection with PDI methods is responsible for initializing the seed point in the region of interest to determine the zero level set. This combination provides the system greater robustness in determining the zero level set that will increase the efficiency in segmenting the region of interest in the shortest possible time. As initialization becomes more stable, the growth and refinement of the region using probabilistic estimates with the parzen window within the level set produces a more accurate outcome. The proposed method was applied and evaluated together with others in the literature in three applications: segmentation of regions with stroke on CT images of the skull, segmentation of the lungs on CT images of the chest, and segmentation of skin lesions on digital images. The results demonstrate the efficiency of FPLS in systems that assist in medical diagnosis. The speed of the method proposed in the segmentation and processing of information for medical diagnosis is promising, presenting efficient and reliable results. It achieves comparable results and, often, is superior to other methods with low computational costs. Therefore, considering the general analysis of the results obtained by the proposed approach, we can conclude that the FPLS is promising in the segmentation of regions of interest. The method showed promise in analyzing healthy, unhealthy, and anomalies patients' images. Therefore, the FPLS can be integrated into medical diagnosis aid systems, either for diagnosis or for the follow-up of diseases throughout treatment, in a more targeted way, for the analysis of stroke in CT images of the skull, of lungs on chest CT images, and of skin lesions on digital images.

Keywords: Active contours. Aid in medical diagnosis. Image Segmentation. Medical Images.

LISTA DE ILUSTRAÇÕES

Figura 1 – Diferenciação dos tipos de AVC (AMERICAN HEART ASSOCIATION AND AMERICAN STROKE ASSOCIATION, 2016).	27
Figura 2 – Doença Pulmonar Obstrutiva Crônica (Fonte: Autor).	28
Figura 3 – Ilustra a imagem da pele humana contendo várias camadas da epiderme, com região de melanoma marcada por células denominadas melanócitos (Fonte: Autor).	29
Figura 4 – Propagação de uma curva fechada $\vec{\phi}$ submetida a um campo de velocidades $(\pm F\vec{\eta})$ (BRAGA, 2016).	31
Figura 5 – Representação da função de <i>level set</i> $\psi(\mathbf{x}, t)$ e da curva $\vec{\phi}(s, t)$ Sethian (1998).	31
Figura 6 – Possíveis estados iniciais da superfície ou <i>level set</i> zero: a) com apenas um elemento; e b) com múltiplos elementos.	32
Figura 7 – Fluxograma da metodologia proposta. A) Correlação entre os três ambientes inseridos no método, a cor vermelha detecta a região de interesse; B') Inicialização via Processamento Digital de Imagem; B'') Inicialização via clustering; C) Definição do <i>level set</i> zero com base na similaridade encontrada entre os centróides das regiões; D) Envio da região definida de nível zero para o método <i>level set</i> baseado na janela de parzen onde a região é refinada com estimativas probabilísticas.	39
Figura 8 – Exemplo da inicialização proposta aplicada na detecção da região acometida pelo AVC para inicialização do <i>level set</i> zero em imagens de TC do crânio.	42
Figura 9 – Exemplo da inicialização proposta aplicada na detecção da região dos pulmões para inicialização do <i>level set</i> zero em imagens de TC do tórax.	43
Figura 10 – Exemplo da inicialização proposta aplicada na detecção da região acometida pelas lesões de pele para inicialização do <i>level set</i> zero em imagens digitais.	43
Figura 11 – Processo de iteração do método proposto em amostras do <i>dataset</i> de AVC. Na legenda, o "C" significa o número de iterações do contorno ativo.	46
Figura 12 – Processo de iteração do método proposto em amostras do <i>dataset</i> de pulmão. Na legenda, o "C" significa o número de iterações do contorno ativo.	47
Figura 13 – Processo de iteração do método proposto em amostras do <i>dataset</i> de pele. Na legenda, o "C" significa o número de iterações do contorno ativo.	48

Figura 14 – Exemplos de amostras do <i>dataset</i> de AVC usadas para avaliar a abordagem proposta neste trabalho. As imagens destacam características diversas, como tamanho, forma, intensidade e contraste, para fornecer uma visão geral da complexidade do conjunto de dados. Cada imagem apresenta desafios únicos para a segmentação, sendo que algumas delas contêm hemorragias em diferentes partes do cérebro, enquanto outras têm um formato mais irregular.	50
Figura 15 – Exemplos de amostras do <i>dataset</i> de pulmão usadas para avaliar a abordagem proposta neste trabalho. As imagens destacam características diversas, como tamanho, forma, intensidade e contraste, para fornecer uma visão geral da complexidade do conjunto de dados.	51
Figura 16 – Exemplos de amostras do <i>dataset</i> de pele usadas para avaliar a abordagem proposta neste trabalho. As imagens destacam características diversas, como tamanho, forma, intensidade e contraste, para fornecer uma visão geral da complexidade do conjunto de dados.	52
Figura 17 – Regiões onde <i>VP</i> , <i>FP</i> , <i>VN</i> e <i>FN</i> são computadas. O círculo ROI representa a região de referência (padrão ouro). O círculo RS representa a região segmentada por um método computacional (Adaptado de Garcia <i>et al.</i> (2015)).	53

LISTA DE TABELAS

Tabela 1	– Representação do modelo de matriz de confusão 2x2 utilizada.	53
Tabela 2	– Resultados de Precisão (Prec), Sensibilidade (Sen) e Especificidade (Esp) com seus respectivos desvios padrão para a base de dados de AVC. Os valores destacados em negrito correspondem ao método proposto e os melhores resultados estão destacados em verde.	59
Tabela 3	– Resultados do Coeficiente de Correlação de Matthews (MCC), Coeficiente de Similaridade (Dice) e Índice de Jaccard (Jac) com seus respectivos desvios padrão. Os valores destacados em negrito correspondem ao método proposto e os melhores resultados estão destacados em verde.	60
Tabela 4	– Tempo de convergência dos métodos avaliados. Os valores destacados em negrito correspondem ao método proposto e os melhores resultados estão destacados em verde.	60
Tabela 5	– Índices quantitativos usando métodos de segmentação não supervisionados. Os valores destacados em negrito correspondem ao método proposto e os melhores resultados estão destacados em verde.	61
Tabela 6	– Índices de similaridade com FPLS em relação a métodos de segmentação não supervisionados. Os valores destacados em negrito correspondem ao método proposto e os melhores resultados estão destacados em verde.	62
Tabela 7	– Índices quantitativos usando métodos de segmentação supervisionados. Os valores destacados em negrito correspondem ao método proposto e os melhores resultados estão destacados em verde.	62
Tabela 8	– Índices de similaridade com FPLS em relação aos métodos de segmentação supervisionados. Os valores destacados em negrito correspondem ao método proposto e os melhores resultados estão destacados em verde.	63
Tabela 9	– Tempo médio de segmentação do FPLS em relação a outros métodos. Os valores destacados em negrito correspondem ao método proposto e os melhores resultados estão destacados em verde.	63

Tabela 10 – Comparação do FPLS com os estudos mais recentes sobre segmentação de lesões de pele considerando Índice de Jaccard (Jac), Coeficiente de Dice (Dice), Sensibilidade (Sen), Especificidade (Esp) e Acurácia (Acc) como métricas de avaliação. Os valores destacados em negrito correspondem ao método proposto e os melhores resultados estão destacados em verde. . . .	64
Tabela 11 – Tempo médio de segmentação por imagem. Os valores destacados em negrito correspondem ao método proposto e os melhores resultados estão destacados em verde.	65

SUMÁRIO

1	INTRODUÇÃO	15
1.1	Estado da arte	17
1.2	Motivação	23
1.3	Objetivos	23
<i>1.3.1</i>	<i>Objetivo Geral</i>	<i>23</i>
<i>1.3.2</i>	<i>Objetivos Específicos</i>	<i>24</i>
1.4	Contribuições	24
1.5	Produção Científica	25
1.6	Organização da Tese	25
2	FUNDAMENTAÇÃO TEÓRICA	26
2.1	Revisão clínica das doenças abordadas	26
<i>2.1.1</i>	<i>Acidente Vascular Cerebral</i>	<i>26</i>
<i>2.1.2</i>	<i>Doença Pulmonar Obstrutiva Crônica</i>	<i>27</i>
<i>2.1.3</i>	<i>Câncer de pele</i>	<i>29</i>
2.2	Level Set	30
2.3	Algoritmo rápido de <i>Level Set</i>	33
2.4	Janela de parzen	34
2.5	Floor of Log	35
2.6	Conclusão do Capítulo	36
3	METODOLOGIA	38
3.1	Etapa 01 - Abertura de Imagens e Pré-Processamento	38
3.2	Etapa 02 - Inicialização da abordagem proposta	40
<i>3.2.1</i>	<i>Etapa 02 B' - Etapa de Clusterização: LBP + Floor of Log</i>	<i>40</i>
<i>3.2.2</i>	<i>Etapa 02 B'' - Filtragem Espacial + Morfologia Matemática</i>	<i>41</i>
<i>3.2.3</i>	<i>Etapa 03 - Interseção entre B' e B''</i>	<i>42</i>
3.3	Etapa 04 - Level set usando uma estimação não paramétrica com base na janela de parzen	44
3.4	Base de dados	46
<i>3.4.1</i>	<i>Análise de Desempenho</i>	<i>49</i>
<i>3.4.1.1</i>	<i>Métricas Quantitativas</i>	<i>53</i>

3.4.1.2	<i>Métricas de Similaridade</i>	55
3.5	Conclusão do Capítulo	57
4	EXPERIMENTOS, RESULTADOS E DISCUSSÕES	58
4.1	Acidente Vascular Cerebral (AVC)	58
4.2	Pulmão	61
4.3	Pele	64
4.4	Conclusão do Capítulo	66
5	CONCLUSÕES E TRABALHOS FUTUROS	67
5.1	Conclusões	67
5.2	Trabalhos Futuros	69
	REFERÊNCIAS	70

1 INTRODUÇÃO

A pesquisa científica tem se mantido atenta à busca por aprimoramentos em algoritmos e metodologias que auxiliam o diagnóstico por meio de exames de Tomografia Computadorizada (TC), Ressonância Magnética (RM) e Imagem Dermatoscópica (ID) (SHARMA *et al.*, 2010; MENDONCA *et al.*, 2013). Para obter resultados mais precisos, acessíveis e rápidos, a análise de imagens médicas pode ser dividida em duas etapas principais: a segmentação da região de interesse (ROI) e a classificação dessa região. A etapa crucial é a segmentação da ROI, pois esse processo permite a delimitação precisa da região, facilitando assim a classificação e o diagnóstico (PHAM *et al.*, 2000).

Dessa forma, vários pesquisadores têm se dedicado a mensurar os potenciais benefícios do uso de algoritmos de Visão Computacional em diversas aplicações médicas, tais como a detecção e a segmentação de patologias (XU *et al.*, 2020; SOUZA *et al.*, 2020) e a classificação de doenças (ALVES *et al.*, 2020). Esses algoritmos são aplicados com base nos sinais extraídos dos exames, e são conhecidos como sistemas de diagnóstico auxiliado por computador (CAD) (SARMENTO *et al.*, 2019). Os sistemas CAD são compostos por algoritmos de alto desempenho que empregam técnicas como processamento de imagem, reconhecimento de padrões, aprendizado de máquina e visão computacional. Tais técnicas permitem a análise automatizada de imagens médicas, visando auxiliar os profissionais de saúde no diagnóstico de doenças e na tomada de decisões clínicas. Porém, em muitas aplicações, o uso de algoritmos com menor custo computacional pode ser igualmente satisfatório ou até superior ao de técnicas mais robustas, tornando esses algoritmos vantajosos por demandarem hardwares menos potentes e mais acessíveis (PRAKASH *et al.*, 2017).

Nesse contexto, este trabalho aborda a aplicação de técnicas de processamento de imagens em dois tipos de exames médicos: imagens dermatoscópicas de lesões de pele e imagens de tomografia computadorizada de acidente vascular cerebral e pulmão.

O melanoma cutâneo, que representa mais de 90% dos casos de câncer de pele, é responsável por 55.500 mortes anualmente em todo o mundo (BOYLE *et al.*, 2004; AKKOOI *et al.*, 2018). Por apresentar diferentes aspectos em sua manifestação, o melanoma é um desafio para o processamento de imagens médicas. Para lidar com esse problema, diferentes técnicas de visão computacional são utilizadas para segmentar as regiões de interesse e identificar características que possam auxiliar no diagnóstico.

As doenças respiratórias, por sua vez, representam um grave problema de saúde

pública (GUAN *et al.*, 2016). Comportamentos de risco, como o tabagismo, a exposição profissional e a poluição atmosférica, contribuem para o aumento dessas doenças (LELIEVELD *et al.*, 2015). A pneumonia, a doença pulmonar obstrutiva crônica (DPOC), a tuberculose, as infecções respiratórias e o câncer pulmonar são algumas das patologias que afetam os pulmões e que são consideradas graves pela Organização Mundial da Saúde (OMS) (ORGANIZATION, 2017). A DPOC, em especial, afeta de 210 milhões a 300 milhões de pessoas em todo o mundo e é estimada como a terceira principal causa de morte no mundo nos próximos dez anos (ORGANIZATION, 2013).

As doenças respiratórias representam um sério problema de saúde pública (GUAN *et al.*, 2016), tendo em vista que muitos dos comportamentos de risco que as causam, como o tabagismo, exposição profissional, patologias do sistema imunológico e poluição atmosférica, são bastante comuns (LELIEVELD *et al.*, 2015). Consequentemente, a saúde da população mundial é uma grande preocupação, conforme apontado pela OMS (ORGANIZATION, 2017). Entre as patologias diagnosticadas nos pulmões, encontram-se a pneumonia, doença pulmonar obstrutiva crônica, tuberculose, infecção respiratória e câncer pulmonar, sendo que todas elas são consideradas graves pela OMS (ORGANIZATION, 2013).

O AVC causa uma taxa de mortalidade anual de 5 milhões e afetam cerca de 15 milhões em todo o mundo, sendo considerado um dos piores traumas do corpo humano (ORGANIZATION, 2019; VASCONCELOS *et al.*, 2020). Além de ser a segunda principal causa de morte no mundo (KATAN; LUFT, 2018), o AVC pode causar diversas sequelas, afetando a fala, a visão e até mesmo causando paralisia (MUKHERJEE *et al.*, 2006). Em termos econômicos, o AVC chega a custar cerca de 3 a 4% dos gastos totais com saúde nos países do ocidente (KATAN; LUFT, 2018), sendo que nos EUA, o custo médio ao longo da vida de uma pessoa que foi afetada por AVC isquêmico, incluindo internação, reabilitação e acompanhamento, é estimado em cerca de US\$ 140.000 (KATAN; LUFT, 2018).

Diante destes levantamentos introdutórios, buscando aproximar a problemática sobre o contexto de possíveis soluções, esta seção aborda diferentes aspectos sociais, econômicos, computacionais, bem como tecnologias associadas ao processamento de imagens médicas, em diferentes soluções. A análise abordada nesta seção tem como propósito apresentar uma visão contextualizada do estudo proposto.

1.1 Estado da arte

A segmentação de imagens ROI tem sido abordada em diferentes contextos e utilizando diversas técnicas. Para segmentação de exames tomográficos de derrame cerebral, a utilização de funções de definição de nível tem se mostrado eficaz. Filho *et al.* (2017a), a evolução e inicialização da região são realizadas com base na densidade cerebral e adaptabilidade de acordo com a faixa de intensidade apresentada nos exames. Rouhi *et al.* (2015) implementaram a segmentação com base em uma rede neural artificial treinada para estabelecer os limites da região a partir de recursos como intensidade, textura e forma da imagem. Enquanto isso, em Körbes e Lotufo (2010), é realizada uma análise do algoritmo clássico de transformação da bacia hidrográfica e objetivam minimizar a influência da ordem de varredura dos *pixels* na imagem.

Já para a segmentação pulmonar em exames tomográficos, o contorno ativo tem sido uma técnica amplamente utilizada. Diversas abordagens foram propostas, como apresentado por Medeiros *et al.* (2019a), Filho *et al.* (2019b), Felix *et al.* (2009), Rebouças Filho *et al.* (2011), Rebouças Filho *et al.* (2014), Xu e Prince (1998), Li e Acton (2006), Alexandria *et al.* (2010). Cada um desses trabalhos destaca uma contribuição na definição dos critérios de crescimento da região, como o uso de Fuzzy Border Detector introduzido por Medeiros *et al.* (2019a), a adoção da topologia definida pela densidade dos *pixels* que formam o contorno apresentado por Felix *et al.* (2009), Rebouças Filho *et al.* (2011), Rebouças Filho *et al.* (2014), e a parametrização dos critérios de evolução utilizando variações do vetor de imagem, como GVF e VFC, como realizaram Xu e Prince (1998), Li e Acton (2006). Alexandria *et al.* (2010) utilizaram a Transformada de Hilbert juntamente com os raios ativos da imagem representada usando coordenadas polares. Essas pesquisas são exemplos de como as ferramentas baseadas em processamento digital de imagem, por meio de modelos matemáticos eficientes, têm se mostrado promissoras para a segmentação de imagens médicas em suas diferentes classes, como a segmentação pulmonar, cardíaca, de lesões cerebrais e de lesões de pele. Tais aplicações têm instigado grandes estudos até os dias atuais e têm sido alvo de inúmeras pesquisas na área médica, com o objetivo de desenvolver novas técnicas e aprimorar as já existentes.

De maneira geral, os contornos ativos são contornos deformáveis que se ajustam de acordo com parâmetros pré-definidos, permitindo sua aplicação em diversas áreas, como rastreamento baseado em imagem de objetos rígidos e não rígidos, detecção e segmentação de objetos, especialmente em imagens separadas por regiões homogêneas, como destacado por Arabnia e Tran (2016). O uso de contornos ativos na área médica tem se mostrado cada vez

mais difundidos, e variações nos cálculos de ajuste dos contornos e sua combinação com outras técnicas têm tornado essa ferramenta promissora em sistemas de auxílio ao diagnóstico, como os sistemas CAD, como mencionado por Han e Wu (2019).

Cientes da ampla capacidade de uso dos contornos ativos para imagens médicas, o trabalho de Filho *et al.* (2017b) buscou validar a aplicabilidade do uso desta técnica em imagens de TC de pulmão. O modelo desenvolvido pelos autores, denominado de *3D Adaptive Crisp Active Contour Method* (3D ACACM), consiste na iniciação por semente no centro da região de interesse, posteriormente, esta semente se ajusta, expandindo e englobando, de forma iterativa, toda a região à ser segmentada de acordo com a energia atrelada ao modelo deformável 3D. A fim de validar o desempenho do método, o algoritmo foi utilizado na segmentação de um total de 40 fatias do exame de TC de pulmão, obtendo 99% de *F-measure*. Entretanto, a fim de garantir maior discussão à cerca do comportamento do modelo proposto para o problema em questão, seria interessante o uso das demais métricas de avaliação encontradas na literatura, abrindo espaço para uma discussão mais ampla e detalhada à cerca dos pontos relativamente importantes do modelo em questão, bem como seu comparativo com modelos encontrados na literatura, trazendo uma discussão mais profunda na temática.

Buscando elevar a discussão já levantada à cerca do uso de contornos ativos nos mais diversos nichos de aplicação, Filho *et al.* (2019a) desenvolveram um novo método denominado *Optimum Path Snakes* (OPS), baseado em contornos ativos, livres de parâmetros pré determinados para mensuração da energia total do modelo de contorno ativo, com início e término de expansão realizados de maneira automática através de cálculos de força balão realizados por iteração nas bordas da região. O modelo foi aplicado em diversos tipos de imagens com finalidade de demonstração visual, como pontos de solda, figuras de áreas fechadas e imagens médicas, sendo este último grupo mensurado também mediante cálculo de métricas de segmentação, mais precisamente *Hausdorff* e Coeficiente *Dice*, alcançando médias superiores à 84% para segmentação de pulmão e AVC Hemorrágico em imagens de TC. Vale ressaltar que o uso de todo o grupo de métricas de avaliação para segmentação trás ao trabalho um maior embasamento técnico para avaliar sua performance nas mais variadas perspectivas. Além disso, o modelo demonstrou ser superado por técnicas mais recente nas métricas abordadas.

Ciente da eficiência desses métodos como ferramenta de segmentação, Medeiros *et al.* (2019) fizeram uso da combinação de um método de contorno ativo adaptativo denominado *Morphological Geodesic Active Contour* (FGAC) e energia externa adaptativa através

de aprendizado profundo para realizar a segmentação do ventrículo esquerdo em imagens de ecocardiograma. Embora os resultados do modelo utilizado tenham sido satisfatório, não trouxeram significativa variação com relação aos modelos de segmentação utilizados pelos autores na comparação, com acurácias médias de 98%. Entretanto, é de grande contribuição a discussão levantada sobre a aplicabilidade do método Geodésico para a segmentação de imagens de ecocardiograma na composição de modelos de segmentação automática.

Na continuidade dos estudos à cerca da generabilidade de aplicações médicas no uso de contornos ativos Geodésicos, além da ciência à cerca dos altos índices de busca para este tipo de aplicação, Vasconcelos *et al.* (2019) realizaram aplicação dessa ferramenta para a segmentação automática de lesões de pele em um *dataset* de imagens dermatoscópicas fornecido em parceria com instituições de saúde. O modelo, denominado de Contorno Ativo Geodésico Morfológico (MGAC), possui inicialização automática, o que o tornou apto à ser comparado com demais técnicas automáticas na literatura. Em seus resultados, o modelo foi capaz de superar outros trabalhos que fizeram uso de aprendizado de máquina, com acurácia média de 98% para o problema em questão, além de um coeficiente *DICE* de 92,09%, demonstrando mais uma vez a boa capacidade de generabilidade dos modelos baseados no uso de Contorno ativo morfológico para aplicação de segmentação de pele lesionada. Vale ressaltar que mesmo para resultados satisfatórios, como o *DICE* em questão, os valores encontram-se superados por modelos mais atualizados, capazes de lidar com a problemática dos pelos neste tipo de imagem, sendo capazes de realizar a segmentação sem grandes perdas para atenuar essa adversidade.

No âmbito da problemática de detecção de doenças pulmonares, além da busca pelo aperfeiçoamento e generabilidade de segmentação, sobretudo com o auxílio de contornos ativos Geodésicos, Medeiros *et al.* (2019b) fizeram uso do FGAC para a segmentação pulmonar em imagens de tomografia computadorizada de tórax. O *dataset* segmentado possui um total de 72 imagens de tomografias de diferentes voluntários cujos pulmões se encontravam em estado saudável, afetados por fibrose e doença pulmonar obstrutiva crônica. O método alcançou baixo tempo de segmentação média por imagem, além de precisão de 98,86%. Além disso, o estudo também trouxe uma discussão proveniente da comparação do modelo com demasiados modelos de segmentação automática encontrados na literatura, de forma à validar a aplicabilidade do contorno ativo Geodésico na problemática de segmentação pulmonar. Estudos envolvendo uma base de dados de maior quantidade de imagens, sobretudo com maiores condições de lesões, como câncer pulmonar, trariam ainda mais riqueza para a discussão, além de aumentar a

confiabilidade à cerca da capacidade de generalização do método para o escopo de segmentação pulmonar lesionado e saudável.

Após realizada a validação da aplicabilidade do uso de contornos ativos Geodésicos nos mais variados tipos de imagens médicas, bem como tendo ciência da importância do desenvolvimento de sistemas CAD para AVC Hemorrágico, Medeiros *et al.* (2020) buscaram validar o MGAC para a segmentação de AVC Hemorrágico em um *dataset* constituído de 100 imagens de Tomografia computadorizada de crânio, todas as imagens apresentavam AVC Hemorrágico em algum ponto da massa cinzenta do paciente. O modelo, denominado Contorno Ativo Geodésico Morfológico adaptativo (Ada-MGAC) consistindo na aplicação automática do MGAC sobre a região de interesse. O método atingiu acurácia média de 99% e baixo tempo para segmentação, comprovando a aplicabilidade do método para este problema, além da comparação com demais trabalhos encontrados na literatura que fizeram uso do mesmo *dataset*. Entretanto, levando em consideração o surgimento de novos modelos baseados em aprendizado de máquina e aprendizado profundo no escopo da segmentação de AVC Hemorrágico, seria interessante uma comparação com estes modelos mais atualizados. Porém, é notório o alto custo computacional para uso de métodos computacionais com uso de *Deep Learning*, bem como o acesso a *dataset* de imagens médicas com grande quantidades de imagens rotuladas, ou segmentadas por especialistas da área medicina, a fim de validar as amostras para possíveis treinamentos em larga escala, exigentes de uma grande quantidade de amostras para se ter bons resultados.

A segmentação de ROI em ID de lesões de pele é diferente das descrições acima. As abordagens selecionadas serão divididas entre aquelas que usam e aquelas que não usam *Deep Learning*. Os trabalhos que não utilizaram *Deep Learning* Vasconcelos *et al.* (2020), Pennisi *et al.* (2016), Patino *et al.* (2018) abordaram a segmentação das lesões com métodos baseados em uma função de *level set*, para estimar a região por triangulação ou para identificar superpixels. O algoritmo em Vasconcelos *et al.* (2020) realiza a evolução da região com base em equações diferenciais. Outra abordagem emprega o algoritmo de Triangulação de Delaunay (PENNISI *et al.*, 2016) para identificar o melanoma e o algoritmo SLIC referenciado a partir da intensidade média dos canais RGB (PATINO *et al.*, 2018). Por outro lado, os métodos baseados em *Deep Learning* como (BADRINARAYANAN *et al.*, 2015; BI *et al.*, 2019; BAGHERSALIMI *et al.*, 2019; AL-MASNI *et al.*, 2018) podem ser divididos em abordagens de alta resolução ou baixa resolução, dependendo da estrutura implementada. Notavelmente, esses métodos não dependem

de etapas de pré-processamento para segmentação, mas requerem um grande número de amostras para realizar o treinamento.

Como foco na segmentação da ROI através do uso de *Deep Learning*, mas também com a inovação tecnológica trazida pelas técnicas do grupo de *Health of things*, os estudos de Xu *et al.* (2020) propuseram uso de um método para detecção de AVC Hemorrágico em imagens de tomografia computadorizada. Sua técnica realizava a pré-classificação da imagem de entrada, como lesionado ou não lesionado pelo AVC Hemorrágico, segmentando a região lesionada posteriormente através do uso da técnica de *transfer learning* para a região de interesse detectada na saída da *Mask R-CNN*. A região detectada é segmentada com auxílio de técnicas de criação de um mapa de região do AVC, técnicas como KNN, Naive Bayes, MLP e demais algoritmos de *Machine Learning*, que foram utilizados para a segmentação mediante uso de *transfer learning*. O método obteve resultados satisfatórios, alcançando médias de 99% para a segmentação de 356 imagens de TC de AVC hemorrágico, o que demonstra a boa eficácia do método. Entretanto, vale ressaltar a baixa quantidade de imagens utilizadas para treinamento dos modelos, além da importância do uso de mais de uma base de dados para validação dos resultados obtidos, e grande poder de processamento com elevado custo computacional.

Inspirados pelos desafios da segmentação de imagens médicas de tórax, através do uso de técnicas de processamento digital de imagem e técnicas de *Deep Learning*, Souza *et al.* (2020) desenvolveram uma ferramenta capaz de classificar e segmentar o pulmão em imagens de TC de tórax através do uso da rede *Mask R-CNN* auxiliada por técnicas de *fine tuning*. A imagem de entrada é classificada quando à presença ou não de pulmão, sendo essa região segmentada para casos de confirmação. A segmentação é iniciada através da *Mask R-CNN* e refinada com uso de *fine tuning* composto pelo método *level set* baseado em janelamento de parzen. O modelo proposto pelos autores obteve acurácia média acima de 98% comprovando assim a eficiência do uso de técnicas de Processamento Digital de Imagens (PDI) para a melhora de modelos *Deep Learning* na segmentação. Entretanto, vale ressaltar que um maior aprofundamento nos parâmetros da rede utilizada, além do uso de uma maior gama de técnicas para *fine tuning* trariam um maior embasamento para a discussão.

Dando continuidade ao embasamento na temática da segmentação de imagens médicas de TC através do auxílio de técnicas de *Deep Learning*, sobretudo para imagens de tórax, Xu *et al.* (2021) fizeram uso da rede *Mask R-CNN* para a segmentação do pulmão em imagens de TC do tórax. O modelo proposto também fez uso de técnicas de processamento digital de imagem

para aplicação de *fine tuning*, ampliando o desempenho do método. As técnicas de *fine tuning* consistiam na combinação do método *level set* baseado em janelamento de parzen, clusterização de imagem pelo método *k-means*, e crescimento de região. O melhor modelo obteve 97% de precisão para o primeiro *dataset* utilizado, e 98% de precisão para o segundo, além de comprovar sua generalização com o uso de dois *datasets*. Entretanto vale ressaltar que embora de extrema importância para a discussão médica, a segmentação pulmonar é apenas o passo inicial para detecção de patologias.

Visando a construção de um modelo generalizado que seja capaz de obter alto desempenho em mais de um tipo de aplicação, Han *et al.* (2020) propuseram um modelo para classificação e segmentação de imagens de TC de tórax e de cérebro, para a segmentação automática de pulmão e AVC Hemorrágico. O modelo classifica a imagem de entrada através do *transfer learning*, que combina extratores *Deep Learning* e classificadores com uso de *Machine Learning*. A segmentação na imagem é condicionada pela classe acusada durante a etapa de classificação, e posteriormente realizada através da combinação da rede *Detectron2* e técnicas de processamento digital de imagens, como o crescimento de região, a clusterização *K-means* e o crescimento de região. O melhor modelo alcançou acurácias médias de 99% para ambos os *datasets* utilizados. Porém vale ressaltar que o desbalançamento na quantidade de imagens das classes presentes no treinamento da classificação, pode afetar diretamente na confiabilidade do resultado.

Desta forma, é possível compreender a grande contribuição de métodos de contorno ativo na literatura, abrangendo diferentes eixos temáticos da pesquisa. O uso de janelamento de parzen combinado a métodos de crescimento de região, o uso do método *level set* fazem parte de diferentes pesquisas encontradas na literatura atual. O uso de *Deep Learning* em diferentes trabalhos, mostra a contribuição direta no processo de segmentação de regiões de interesse, pois o processo da técnica de *fine tuning* é composta por diferentes métodos consolidados, com a finalidade de se obter melhores resultados para o problema de reajuste ao contorno do objeto (encontrar o contorno do objeto). Desta forma, entende-se que mesmo com o acesso de grande poder computacional, o uso de técnicas otimizadas e com baixo custo computacional, trouxeram grandes contribuições para segmentação de diferentes objetos de interesse.

1.2 Motivação

Na literatura, várias abordagens têm sido propostas para as tarefas de segmentação de regiões de interesse em imagens médicas. Embora existam diversas opções disponíveis, ainda há espaço para melhorias na eficiência e precisão desses métodos. Com o objetivo de contribuir nessa área, este trabalho propõe uma nova abordagem para segmentação de regiões de interesse em imagens médicas, chamada *FLog Parzen Level Set* (FPLS).

Diferente das abordagens da literatura mencionadas, que apresentam diferentes limitações em termos de velocidade e precisão, o método FPLS combina o algoritmo de janela de parzen para estimativa não paramétrica com o método *level set* para produzir uma segmentação mais rápida e precisa da região de interesse em imagens médicas. O uso de Floor of Log para inicialização do contorno ativo proporciona maior precisão na detecção da região de interesse, enquanto a utilização da janela de parzen permite que a segmentação seja realizada em baixas iterações, aumentando a eficiência computacional.

Além disso, o método proposto é adaptável a diferentes tipos de imagens médicas, incluindo imagens dermatoscópicas e tomografias computadorizadas. As principais características do método incluem baixas iterações para segmentação em alta velocidade, adaptabilidade a diferentes tipos de imagens médicas e inicialização do contorno ativo com alta precisão.

Em resumo, o *FLog Parzen Level Set* é uma abordagem inovadora para a segmentação de regiões de interesse em imagens médicas, oferecendo maior eficiência computacional e precisão na detecção de regiões de interesse em comparação com as abordagens existentes na literatura. Em suma, a abordagem proposta é uma contribuição significativa para a área de segmentação de imagens médicas e tem o potencial de melhorar significativamente a qualidade e eficácia dos cuidados de saúde.

1.3 Objetivos

1.3.1 *Objetivo Geral*

Esta tese possui o objetivo geral de propor uma abordagem de *level set* usando uma estimação não paramétrica com base na janela de parzen para segmentação automática de regiões de interesse em imagens médicas visando o auxílio ao diagnóstico médico.

1.3.2 *Objetivos Específicos*

Dentre os objetivos específicos a serem atingidos nesta tese estão:

- introduzir métodos de PDI para auxílio ao diagnóstico médico relacionados ao AVC, DPOC e lesões de pele;
- propor uma abordagem de inicialização do método *level set* baseada na combinação do uso da clusterização por Floor of Log e filtragem espacial com morfologia matemática;
- propor uma abordagem generalista do método *level set* utilizando uma estimação não paramétrica baseada na janela de parzen;
- comparar a abordagem proposta com métodos de segmentação consolidados, e outros recentes, existentes na literatura na segmentação em três aplicações visando auxílio ao diagnóstico médico (segmentação dos pulmões em imagens de TC do tórax, segmentação de acidente vascular cerebral em imagens de TC do crânio e segmentação de lesões de pele em imagens digitais);

1.4 **Contribuições**

As contribuições desta tese são as seguintes:

- inicialização automática do *level set* zero baseado na interseção da clusterização por Floor of Log e do resultado obtido da filtragem espacial combinado com morfologia matemática dentro das regiões acometidas por acidente vascular cerebral em imagens de TC do crânio;
- inicialização automática do *level set* zero baseado na interseção da clusterização por Floor of Log e do resultado obtido da filtragem espacial combinado com morfologia matemática dentro dos pulmões em imagens de TC do tórax;
- inicialização automática do *level set* zero baseado na interseção da clusterização por Floor of Log e do resultado obtido da filtragem espacial combinado com morfologia matemática dentro das regiões acometidas por lesões de pele em imagens digitais;
- proposição de método *level set* utilizando uma estimação não paramétrica baseada na janela de parzen generalista para segmentação de objetos em imagens digitais;
- método automático de segmentação de regiões de interesse desde inicialização do *level set* zero, e com evolução do mesmo utilizando uma estimação não paramétrica baseada na janela de parzen, evoluindo até a parada automática quando a região estabiliza o movimento do contorno.

1.5 Produção Científica

O seguinte artigo é resultado dessa pesquisa:

- REBOUCAS, ELIZANGELA S.; MEDEIROS, FATIMA N. S.; MARQUES, REGIS C. P.; CHAGAS, JOÃO VICTOR S.; GUIMARÃES, MATHEUS T.; SANTOS, LUCAS O.; MEDEIROS, ALDISIO G.; PEIXOTO, SOLON A.. *Level set approach based on parzen window and floor of log for edge computing object segmentation in digital images*. Applied Soft Computing, v. 105, p. 107273, 2021. DOI: <<https://doi.org/10.1016/j.asoc.2021.107273>>.

1.6 Organização da Tese

O restante desta tese está organizada da seguinte forma:

Capítulo 2: Demonstra a contextualização do problema do Acidente Vascular Cerebral e da doença Pulmonar Obstrutiva Crônica, além da apresentação do exame utilizado para detectar as lesões que precedem o câncer de pele do tipo melanoma. Também serão discutidos métodos de auxílio ao diagnóstico encontrados na literatura, que utilizam processamento digital de imagens para ajudar no diagnóstico dessas condições médicas.

Capítulo 3: Apresenta uma explicação da teoria por trás do contorno ativo tradicional para a segmentação de imagens médicas.

Capítulo 4: Fornece uma descrição detalhada da abordagem de segmentação proposta, chamada *Flog Parzen Level Set (FPLS)*. Neste capítulo, são descritas a aquisição das imagens e as métricas de avaliação usadas neste trabalho.

Capítulo 5: Apresenta e discute os resultados obtidos a partir da abordagem proposta em exames de tomografia computadorizada de pulmão e acidente vascular cerebral, além de imagens digitais de lesões de pele. São discutidas as vantagens e limitações da abordagem em cada um desses casos.

Capítulo 6: Apresenta as conclusões e contribuições desta tese, bem como as perspectivas de trabalhos futuros. Este capítulo resume os principais resultados obtidos e destaca a relevância da abordagem proposta para a área de processamento digital de imagens médicas.

2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo contextualiza o problema do Acidente Vascular Cerebral (AVC), da Doença Pulmonar Obstrutiva Crônica (DPOC) e do câncer das lesões de pele, todos os *dataset* das imagens utilizadas neste trabalho, os tipos de exames e métodos computacionais baseados em Processamento Digital de Imagens (PDI) para o auxílio ao diagnóstico médico.

2.1 Revisão clínica das doenças abordadas

Nas seções seguintes serão abordadas brevemente as doenças que motivam as segmentações das regiões em análise desta tese visando o auxílio ao diagnóstico médico com a proposta de realizar a segmentação automática destas regiões de interesse.

2.1.1 *Acidente Vascular Cerebral*

O Acidente Vascular Cerebral, também conhecido como "derrame", ocorre quando o fluxo sanguíneo para uma determinada área do cérebro é interrompido. Quando isso acontece, as células do cérebro são privadas de oxigênio e morrem. Quando as células do cérebro morrem durante um acidente vascular cerebral, capacidades controladas pela referida área do cérebro, tais como a memória e o controle muscular são perdidas (REKIK *et al.*, 2012).

O AVC constitui um frequente e significativo problema de saúde, com elevados índices de morbidade e mortalidade, e por isso tem sido um dos maiores desafios para a saúde pública e a medicina como um todo. Esta doença afeta os vasos que fornecem sangue para o cérebro. Segundo Manzi *et al.* (2003) e Gonçalves *et al.* (2004), o AVC ocorre tanto pela falta de fornecimento de sangue para uma determinada área do cérebro, conhecido como AVC isquêmico (AVCi), quanto pelo sangramento devido ao rompimento de um vaso sanguíneo, AVC hemorrágico (AVCh), como mostra a Figura 1.

O AVC do tipo hemorrágico é causado quando um vaso sanguíneo rompe dentro ou sobre a superfície do cérebro. Por consequência deste rompimento do sangue para o tecido cerebral em alta pressão, o dano causado por este tipo de AVC pode ser maior do que o dano causado por AVC isquêmico (CANCELA, 2008).

O foco desse estudo é o AVC do tipo hemorrágico, que é responsável por 40% de todas as mortes por AVC. Devido à elevada taxa de mortalidade, a detecção rápida da região hemorrágica é crucial para o diagnóstico clínico (SUN *et al.*, 2015). A Tomografia

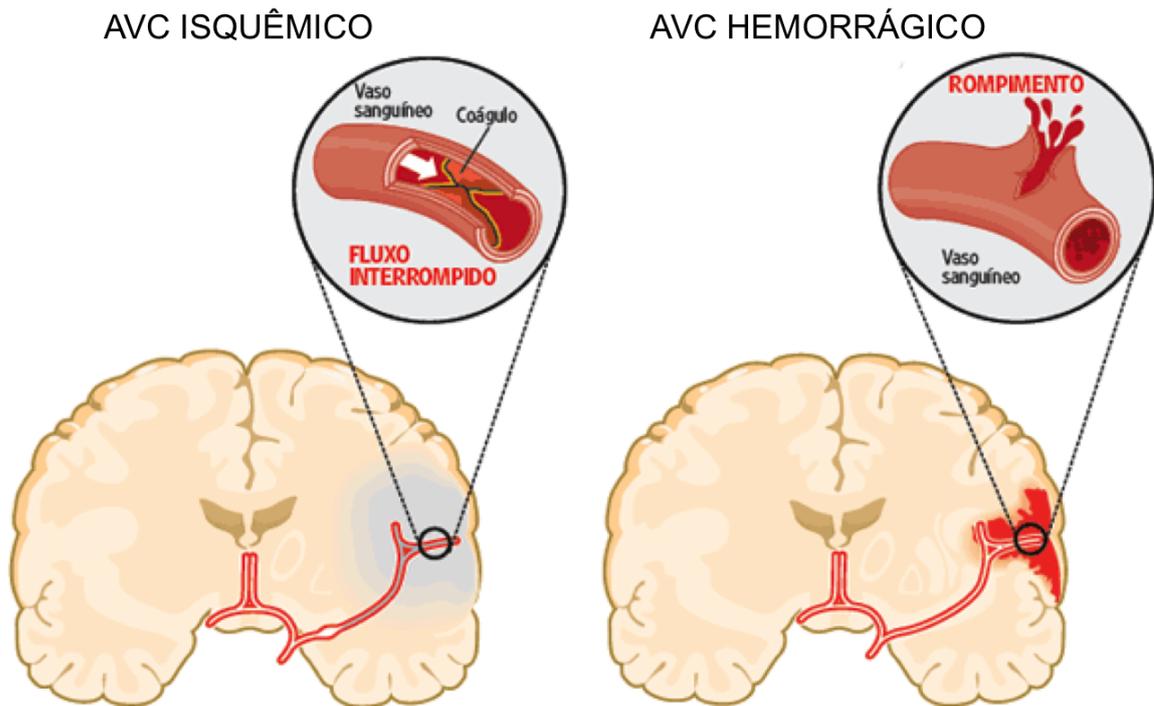


Figura 1 – Diferenciação dos tipos de AVC (AMERICAN HEART ASSOCIATION AND AMERICAN STROKE ASSOCIATION, 2016).

Computadorizada, que é rápida e menos dispendiosa do que outros exames, ainda é o exame mais comumente solicitado para avaliar pacientes com suspeita de AVC. Este exame permite ao especialista verificar a severidade dos danos através da avaliação visual (MESSAY *et al.*, 2010). No entanto, nas primeiras horas da evolução do AVC, as alterações nos exames de TC são sutis, o que torna mais difícil o diagnóstico pelo médico especialista. Além disso, a abordagem padrão com base na delimitação manual da lesão, é demorada e depende do operador (GILLEBERT *et al.*, 2014).

2.1.2 Doença Pulmonar Obstrutiva Crônica

Alguns fatores envolvem algum risco adicional para o aparecimento de doenças pulmonares, incluindo poluição, estilo de vida relacionado ao sedentarismo, tabagismo, o que afeta significativamente a proporção do número de patologias pulmonares por ano (CHATTERJEE *et al.*, 2019).

A doença pulmonar obstrutiva crônica, intitulada na literatura como (DPOC), decorre da delimitação do fluxo de oxigênio ocasionada por inflamação originadas de toxinas expelidas no ar e respiradas por indivíduos, causando insuficiência respiratória aguda ou crônica. A DPOC ocasiona diferentes complicações trazendo danos para saúde do indivíduo, como insuficiência

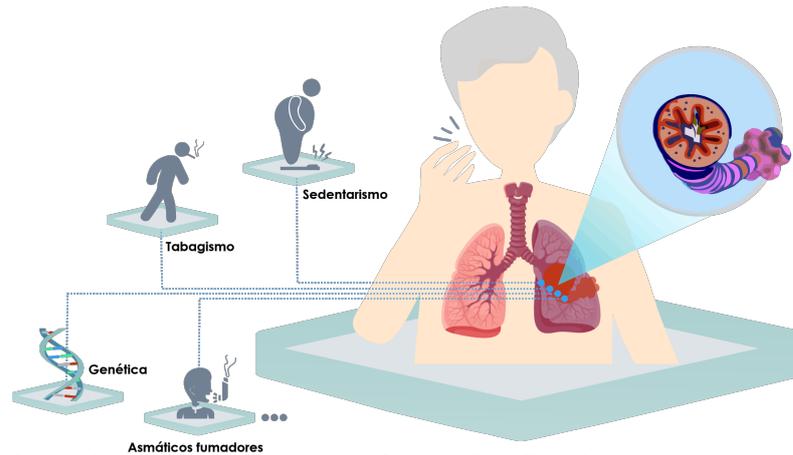


Figura 2 – Doença Pulmonar Obstrutiva Crônica (Fonte: Autor).

cardíaca, descompensação aguda, etc.. Em alguns casos, é preciso a realizar cirurgia para redução do volume pulmonar afetado, ou até mesmo transplante de pulmão. Estimasse que cerca de 50% dos pacientes com doença pulmonar obstrutiva crônica grave morrem em até 10 anos após o diagnóstico de confirmação da patologia (KARAGIANNIS *et al.*, 2020).

A DPOC é uma doença heterogênea com patologias pulmonares, incluindo bronquite crônica, interrupção das vias aéreas e enfisema que prejudicam o funcionamento dos pulmões. Possui inúmeras comorbidades sistêmicas além da doença cardiovascular, a colite e osteoporose também são patologias originadas, sendo o principal fator de risco a inalação de fumaça de cigarro, poluição (BOWERMAN *et al.*, 2020). Na Figura 2 aborda os principais aspectos correlacionados a DPOC, bem como a representação da geração do problema de saúde, atacando os pulmões, obstruindo os alvéolos pulmonares, responsáveis por carregar oxigenação para o corpo humano, sua obstrução acarreta em vários problemas de saúde graves.

Segundo Organization (2017), incidentes como estes são sinais alarmantes em relação a saúde mundial, trazendo grande preocupação no contexto em políticas públicas, saúde e sociedade. Porém a diversidade destas patologias podem ser diagnosticadas em meio a sua grande variedade entre as doenças respiratórias, tais como: tuberculose, asma, pneumonia, fibrose pulmonar, Doença Pulmonar Obstrutiva Crônica (DPOC), dentre outras, incluindo câncer de pulmão e (DIP) Doenças Intersticiais Pulmonares, cujo representa um conjunto de doenças pulmonares com cerca de 200 patologias relacionadas ao pulmão, dentre elas, várias classificadas graves pela Organização Mundial de Saúde (OMS) (ORGANIZATION, 2013).

Se tratando de doenças pulmonares, a DPOC tornou-se a terceira causa de morte no mundo (BOWERMAN *et al.*, 2020), e a quinta causa de insuficiência respiratória, afetando em grande parte, pessoas a partir de 45 anos, isso representa atualmente 10% da população mundial

(MARCO *et al.*, 2004).

2.1.3 Câncer de pele

O câncer de pele é um tipo de câncer potencialmente curável, dividido em duas categorias, melanoma e não melanoma. Apenas 20% dos pacientes desenvolvem a doença sem possibilidade de cura (BOYLE *et al.*, 2004; CORRIE *et al.*, 2014). O melanoma cutâneo é responsável por mais de 90% de todos os melanomas, causando até 55.500 mortes anuais, a taxa de início e mortalidade da doença variam significativamente em todo o mundo (BOYLE *et al.*, 2004; AKKOOI *et al.*, 2018). Uma vez que o melanoma é potencialmente curável, a falta de detecção primária e procedimentos de tratamento precoce têm uma influência significativa na taxa de mortalidade da doença (AKKOOI *et al.*, 2018).

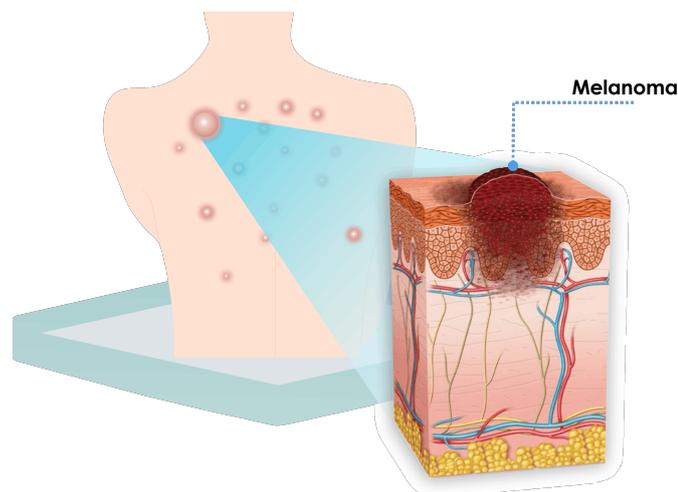


Figura 3 – Ilustra a imagem da pele humana contendo várias camadas da epiderme, com região de melanoma marcada por células denominadas melanócitos (Fonte: Autor).

A rápida identificação e tratamento têm considerável influência no potencial de cura do melanoma. Diversas técnicas são propostas para auxiliar no diagnóstico na literatura. Uma delas é a dermatoscopia, que auxilia no processo de seleção da região por meio da utilização de um instrumento óptico acoplado a um sistema de iluminação para ampliar a região doente. O uso de imagens dermatoscópicas permite uma melhor delimitação dos limites da região lesada (MENDONCA *et al.*, 2015). A Figura 3 ilustra a imagem da pele humana, na imagem é possível identificar as várias camadas da pele até a epiderme nas camadas mais profundas, a imagem ilustra a região do melanoma por meio células denominadas melanócitos, representada pela região escura entre a superfície rasa da pele, percorrendo a região de profundidade média da

epiderme, até regiões mais profundas em contato com diferentes microvasos do tecido da pele humana.

Entre os diferentes tipos, o câncer de pele é o mais ativo na década atual, o fato de a pele ser o maior órgão do corpo humano, é considerado o mais comum em seres humanos. Na literatura é classificado em duas principais categorias. Geralmente é classificado nas categorias principais: melanoma e câncer de pele não melanoma. Assim, de acordo com os levantamentos realizados na literatura, o melanoma é uma doença extremamente perigosa, tipo raro e mortal de câncer de pele. De acordo com estatísticas do American Cancer Sociedade, os casos de câncer de pele melanoma representam apenas 1% do total de casos, mas resultam em maior taxa de mortalidade, aumentando o índice de mortalidade de câncer no mundo (DILDAR *et al.*, 2021).

Se tratando do desenvolvimento e evolução da doença, o melanoma se desenvolve por meio de células melanócitos, na qual se expandem pela pele de forma descontrolada, criando um tumor cancerígeno, podendo afetar diferentes áreas do corpo. A decorrência da região do melanoma são mais comum o surgimento em regiões expostas a raios solares, podendo surgir também em diferentes regiões do corpo humano, formados nas camadas médias e superiores da epiderme. Para o diagnóstico preciso, é uso método de biópsia para detecção, o procedimento remove amostras da pele lesionada com o objetivo de determinar, classificar em melanoma e não melanoma. Um processo invasivo e doloroso com objetivo de identificar regiões na área lesionada. Atualmente, diferentes técnicas são utilizadas para não só classificar regiões de melanoma, mas também para segmentar regiões de interesse, para isso são aquisitadas na literatura diferentes imagens de regiões de pele, contendo melanoma, onde são usadas técnicas de visão computacional detecção, classificação e segmentação (DILDAR *et al.*, 2021).

2.2 Level Set

A formulação da teoria de *level set* proposta por Sethian (1998) é baseada na equação de Hamilton-Jacobi. Esta teoria afirma que uma curva fechada $\vec{\phi}: \mathbb{R}^2 \times \mathbb{R}^+ \rightarrow \mathbb{R}$ evolui devido a um campo de velocidade $\pm F \vec{\eta}$, em que $(\pm \vec{\eta})$ é o vetor unitário que é perpendicular a $\vec{\phi}$, como ilustra a Figura 4.

No domínio contínuo, o movimento da curva é uma consequência do movimento da superfície $\psi(\mathbf{x}, t)$, na qual $\vec{\phi}$ está incorporado de acordo com:

$$\vec{\phi}(s, t) = \{\mathbf{x} | \psi(\mathbf{x}, t) = 0\}, \mathbf{x} \in \mathbb{R}^2, \quad (2.1)$$

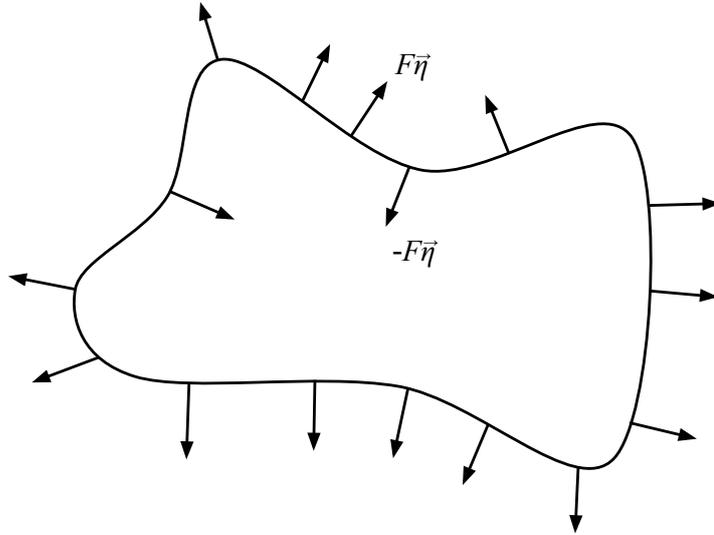


Figura 4 – Propagação de uma curva fechada $\vec{\phi}$ submetida a um campo de velocidades ($\pm F\vec{\eta}$) (BRAGA, 2016).

em que $s \in \mathbb{R}^2$ é a coordenada da curva $\vec{\phi}$ e $t \in \mathbb{R}^+$ é o tempo de evolução. Assim, uma curva fechada $\vec{\phi}(s, t)$ é representada implicitamente como o nível zero de uma função *level set* $\psi(\mathbf{x}, t)$, a qual consiste de um conjunto de curvas de níveis que variam de um nível inferior negativo até um nível superior positivo, como ilustra a Figura 5 (MARQUES, 2011). Por convenção, considera-se a região interna à curva $\Omega_1 = \{\mathbf{x} | \psi(\mathbf{x}, t) < 0\}$ e a região externa à curva $\Omega_2 = \{\mathbf{x} | \psi(\mathbf{x}, t) > 0\}$.

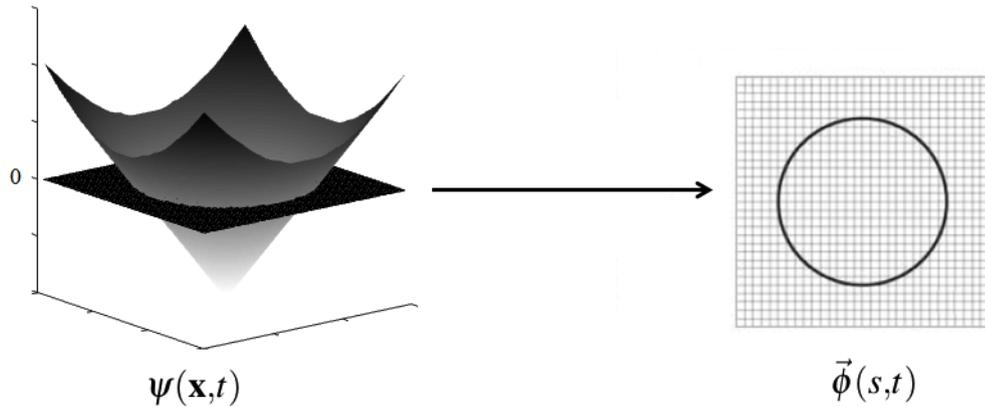


Figura 5 – Representação da função de *level set* $\psi(\mathbf{x}, t)$ e da curva $\vec{\phi}(s, t)$ Sethian (1998).

O processo de evolução da função de *level set* é expresso como (SETHIAN, 1998):

$$\psi^{k+1} = \psi^k + \Delta t \cdot (F_{prop} + \varepsilon \mathcal{K}) \cdot |\nabla \psi^k|, \quad (2.2)$$

em que ψ^k é a função do *level set*, Δt é o passo de tempo, e $F_{prop} + \varepsilon \mathcal{K}$ é a função de evolução. O operador $|\nabla \psi^k|$ representa a magnitude do gradiente. A função de evolução compreende um termo de propagação (ou velocidade) F_{prop} e um termo de regularização $\varepsilon \mathcal{K}$ com base na

curvatura de ψ^k , em que $\varepsilon \in \mathbb{R}$ é uma constante de normalização e a curvatura \mathcal{K} é calculada como (SETHIAN, 1998):

$$\mathcal{K} = \frac{\psi_{xx}\psi_y^2 - 2\psi_x\psi_y\psi_{xy} + \psi_{yy}\psi_x^2}{\sqrt{(\psi_x^2 + \psi_y^2)^3}}. \quad (2.3)$$

Os índices (x, y) e (xx, yy, xy) na Equação 2.3 indicam as derivadas centrais de primeira e segunda ordem de ψ^k , respectivamente.

O *level set* zero é o estado inicial da superfície (ou função *level set*) e consiste de uma imagem com as mesmas dimensões da imagem a ser segmentada. O *level set* zero pode ser composta por um único elemento ou por vários elementos desconectados, os quais podem se unir ou se dividir durante a evolução, a fim de delimitar a região de interesse.

A Figura 6 apresenta dois exemplos de *level set* zero em que a curva $\vec{\phi}(s, 0)$ está em vermelho, Ω_1 em branco e Ω_2 em preto. A Figura 6(a) mostra um *level set* zero em que Ω_1 é composto por apenas um elemento e a Figura 6(b) exibe um *level set* zero em que Ω_1 é composto por vários elementos desconectados.

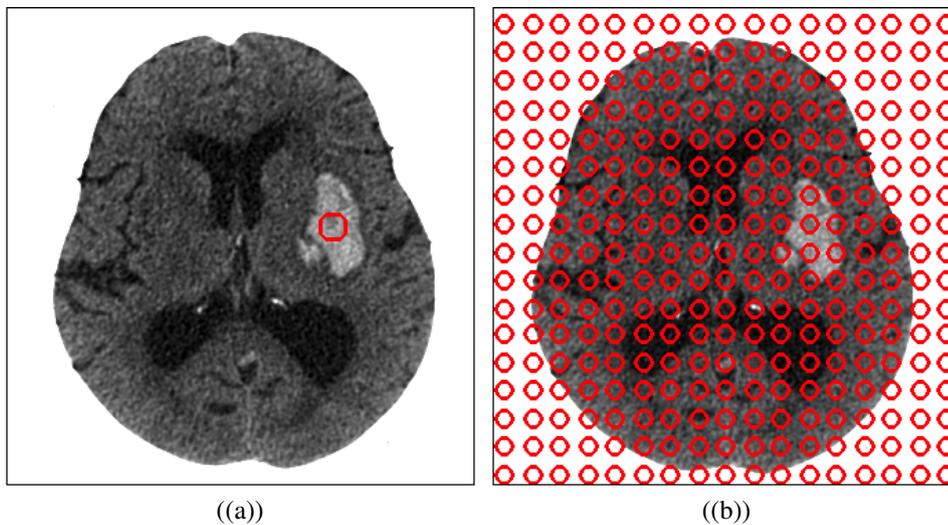


Figura 6 – Possíveis estados iniciais da superfície ou *level set* zero: a) com apenas um elemento; e b) com múltiplos elementos.

O método *level set* é capaz de rastrear curvas complexas, alterando a topologia da região afetada, como o surgimento de picos e cantos afiados, a mudança da área. O rastreamento das superfícies em movimento realizada pelo *level set* se dá de forma numérica, na qual um campo auxiliar é definido sobre o domínio de interesse, e suas bordas são redefinidas, coordenada à coordenada, de acordo com cálculos produzidos por modelos matemáticos. A continuidade da forma da região de interesse é assegurada pela continuidade das funções de forma, isto é, as

bordas são redimensionadas de forma simétrica, respeitando a composição da região (LIU *et al.*, 2018).

A variável ϕ , é definida como sendo o valor do campo de conjunto de níveis. O campo de nível é definido em um domínio de superfície ϕ , que coincide com o plano da interface. A fissura da interface é então definida pelo valor de ϕ , na qual $\phi > 0$ indica fissura, e $\phi < 0$ indica que a superfície deve permanecer intacta. A movimentação da interface de superfície para a superfíeis fissurada se dá de acordo com a técnica de cálculo, que aponta se as coordenadas da interface para aquele ponto no domínio de superfície irão para fora, dilatando a interface, ou para dentro, erodindo a interface (KATOPODES, 2018).

Essa técnica é abordada de maneira abrangente, nas mais diversas áreas, de aplicações da área da mecânica, até aplicações médicas envolvendo uso de modelos computacionais, como segmentação e detecção de regiões afetadas por patologias em exames (GIBOU *et al.*, 2018).

2.3 Algoritmo rápido de *Level Set*

O algoritmo rápido de *level set* proposto por Braga (2016) utiliza conexões teóricas entre filtros da mediana, operadores de morfologia matemática e equações diferenciais parciais geométricas. O processo de iteração do filtro da mediana é equivalente a resolver a equação diferencial parcial geométrica (EDP) dada por (CASELLES *et al.*, 2000)

$$f(\psi) = \mathcal{K} |\nabla \psi|, \quad (2.4)$$

em que \mathcal{K} é descrito pela Eq. (2.3) e $|\nabla \psi|$ é a magnitude do gradiente.

A formulação original da técnica *level set*, dada pela Eq. (2.2), utiliza a EDP da curvatura para fins de regularização da frente. Como visto na Seção 2.2, o cômputo de \mathcal{K} envolve derivadas de primeira e segunda ordem, o que é computacionalmente demorado. A fim de reduzir o custo computacional, o algoritmo *level set* proposto por Braga (2016) utiliza o filtro da mediana, que consiste de um filtro não paramétrico, para regularizar a frente ao invés de utilizar a curvatura \mathcal{K} .

A principal razão para utilizar o filtro da mediana de forma iterativa para fins de regularização é que este filtro consegue uma redução significativa do tempo computacional sem suavizar o sinal excessivamente. Além disso, o algoritmo rápido proposto adota o gradiente morfológico para evitar possíveis inconsistências ao se calcular derivadas numéricas.

Assim, o algoritmo proposto por Braga (2016) evolui sob o modelo:

$$\psi_{\bar{r}}^{k+1} = \psi^k + \Delta t \left[\max(F, 0)(\psi^k \oplus E) - \min(F, 0)(\psi^k \ominus E) \right], \quad (2.5)$$

em que $\psi_{\bar{r}}$ refere-se à superfície não regularizada e E é um elemento estruturante com forma de disco de raio 1. Os operadores \oplus e \ominus representam as operações morfológicas de dilatação e erosão, respectivamente. Braga (2016) afirma que o raio do elemento estruturante pode ser ajustado. Porém, raios de valores maiores do que 1 causam borramento do gradiente morfológico. Após o cômputo de $\psi_{\bar{r}}$, a superfície é regularizada por

$$\psi^{k+1} = MedFilt_4 \left[\psi_{\bar{r}}^{k+1} \right], \quad (2.6)$$

em que o operador $MedFilt_4[\cdot]$ indica uma filtragem mediana com uma vizinhança de conectividade 4.

O filtro é computado em uma vizinhança com 4 conexões, como na regularização clássica por curvatura, que é solucionada pela utilização de derivadas verticais e horizontais. A utilização do *kernel* de vizinhança 4 reduz o custo computacional na aplicação do filtro da mediana (BRAGA, 2016).

2.4 Janela de parzen

O janelamento de parzen é um método de estimação de densidade de probabilidade não paramétrico, que calcula a probabilidade de um determinado ponto A pertencer a um hipercubo $R = Z_{i_k}^{i=1}$ de dimensionalidade D (CHAGAS *et al.*, 2020).

Para a realização da estimação, o método de parzen utiliza uma função *kernel* (δ), não negativa e de parâmetro de suavização H , que consiste em uma janela de tamanho fixo, na qual são estimados pesos para os elementos de acordo com sua distância no campo, os elementos mais próximo do valor estimado tem maior peso do que os pesos com valor mais distante, essa operação é representada na Equação 2.7:

$$p(z) = \frac{1}{n} \sum_{i=1}^{nH} \delta_n(z - z_i), \quad (2.7)$$

em que $p(z)$ representa a probabilidade do *pixel* pertencer ou não à região, z representa o *pixel*, δ é a função kernel usada para limitar a vizinhança do *pixel*, h é o tamanho da aresta da região, e n é o número total de *pixels* da região (YEUNG; CHOW, 2002).

A escolha do *kernel*, bem como a escolha do valor parâmetro de suavização H afetam diretamente nos resultados de saída da função, pois a escolha de um parâmetro correto, para a

dada problemática proposta, impacta diretamente na compreensão e estimação da probabilidade dos mesmos (TSENG; NGUYEN, 2020).

Para a melhor estimação de H , algumas técnicas são apontadas na literatura, como a técnica de minimização do erro médio quadrado integrado, que se baseia no processo de expansão da série de Taylor, na segunda derivada segunda da densidade real das amostras, no tamanho da amostras e na função *kernel* utilizada para exprimir o melhor valor do parâmetro de suavização H . Quando H é grande a estimativa possui baixa resolução, já quando H adquire um valor maior, a estimativa se torna sensível a ruídos. (TSENG; NGUYEN, 2020).

No que diz respeito à função *kernel*, devido à natureza não paramétrica dos dados utilizados, não é possível conhecer a função geradora dos dados, dessa forma, pressupõe-se que os dados pertencem à uma distribuição normal. Dessa forma, a função mais utilizada é Gaussiana. A função Gaussiana é suavizada e, portanto, a função de densidade estimada $p(z)$ também possui variações mais suaves, principalmente com o valor H certo. Uma vantagem do *kernel* gaussiano, é que se assumida uma forma especial da família Gaussiana na qual a função é radialmente simétrica, a função pode ser especificada completamente apenas por um parâmetro de variação (ARCHAMBEAU *et al.*, 2006). Assim, $p(z)$ pode ser expresso como uma mistura de núcleos gaussianos radialmente simétricos com variância comum δ (VINCENT; BENGIO, 2003), determinada pela Equação 2.8.

$$\delta(z) = \frac{1}{\sqrt{(2\pi)^d |C|}} e^{-\frac{1}{2}(z_i - z)' C^{-1} (z_i - z)}, \quad (2.8)$$

em que C representa a matriz de covariância $d \times d$ onde d representa a dimensão, $|C|$ é o determinante de C , z e z_i são os *pixels*.

Devido ao janelamento de parzen ser pouco sensível às amostras não paramétricas, ter alta generalidade, e se ajustar a qualquer problemática (desde que receba os parâmetros específicos de *kernel* e de elemento de suavização), o janelamento de parzen é comumente utilizado na literatura para a composição de métodos computacionais para as mais variadas aplicações, como segmentação de imagens médicas (HAN *et al.*, 2020), diagnóstico de falhas (ISLAM *et al.*, 2018) e outros.

2.5 Floor of Log

O método Floor of Log (FoL), proposto por Peixoto *et al.* (2020a), é um algoritmo de agrupamento de dados através da compressão desses dados. Este método permite que o objeto

de interesse seja destacado das demais regiões de uma forma mais leve e rápida, mantendo a eficiência que seria obtida usando recursos não compactados.

A partir de um conjunto de dados, uma função logarítmica com uma base selecionada é aplicada para alcançar uma transformação linear dos dados. Por ser uma função logarítmica, essa transformação é capaz de gerar valores aproximados próximos uns dos outros. Em seguida, uma função de base é aplicada na saída da função logarítmica, de modo que apenas o limite inferior dessa saída será preservado, ou seja, sua parte inteira. Portanto, diferentes tipos de agrupamento de dados ocorrerão dependendo da base do logaritmo utilizada (PEIXOTO *et al.*, 2020b).

Quando os dados utilizados são valores de *pixel*, eles obterão valores semelhantes após a aplicação de uma função *step*, que removerá a parte fracionária dos dados (PEIXOTO *et al.*, 2020a). A Equação 2.9 abaixo representa a função principal do método de clusterização:

$$f(x) = \lfloor \log_b(x + 1) \rfloor, \quad (2.9)$$

em que b é a base logarítmica da função.

Peixoto *et al.* (2020b) explica que embora o processo de compressão seja elementar, mas robusto, um bom resultado de compressão está relacionado à base logarítmica utilizada.

Em Peixoto *et al.* (2020b), o algoritmo realiza uma compressão de características para aplicações de reconhecimento facial, conseguindo alcançar ótimos resultados mantendo a precisão das informações e integrar com sistemas de computação de borda. Já em Peixoto *et al.* (2020a) este método foi utilizado na segmentação 3D do pulmão em imagens de TC.

2.6 Conclusão do Capítulo

Neste capítulo foi contextualizado o problema do AVC, da DPOC e do câncer das lesões de pele, a importância de diagnosticar precocemente estas doenças, e principalmente delimitar a região afetada por este quadro clínico, que é o foco deste estudo. Em seguida, foram apresentados o método *level set* proposto por Sethian (1998) e base método de segmentação base da proposta desta tese, o método de estimação de densidade de probabilidade não paramétrico com base na janela de parzen e o método Floor of Log que foi utilizado na etapa de inicialização da abordagem proposta neste trabalho. O próximo capítulo apresenta a metodologia proposta para segmentação de imagens médicas TC do crânio e pulmão, como imagens dermatoscópicas de câncer de pele, que consiste de uma nova abordagem para iniciação do método de *level*

set, bem como de um modelo de propagação de verossimilhança baseado na técnica janela de parzen.

3 METODOLOGIA

Neste capítulo, é apresentada a formulação da proposta de segmentação chamada *Flog Parzen Level Set*. Para melhorar os resultados sem afetar os custos computacionais, foi guiada a escolha da janela de parzen e do estágio de clusterização utilizando LBP e Flog, resultando em um *cluster* mais robusto que oferece mais confiabilidade nas etapas do processo sem aumentar os requisitos computacionais. Além disso, essa combinação mantém a precisão do refinamento final com base em estimativas probabilísticas. Em outras palavras, a abordagem proposta foi projetada para melhorar a precisão da segmentação sem aumentar os requisitos de processamento, tornando-a mais eficiente e prática para uso em ambientes clínicos. A Figura 7 mostra o fluxograma desta abordagem.

O algoritmo é dividido em quatro blocos: abertura das imagens, pré-processamento, inicialização da abordagem proposta e segmentação da região de interesse utilizando o método de contorno ativo *level set* com uma estimativa não paramétrica baseada na janela de parzen.

3.1 Etapa 01 - Abertura de Imagens e Pré-Processamento

A abordagem proposta começa abrindo a imagem. Para isso, utilizamos imagens digitais de um conjunto de dados de imagens RGB, bem como dois conjuntos de dados de imagens DICOM (*Digital Imaging and Communications in Medicine*), que são utilizados na área médica. Cada conjunto de dados possui características específicas, o que exige a realização de etapas de pré-processamento para ajustar a imagem para a próxima etapa. No caso das imagens médicas, o processo envolve o uso do janelamento para obter uma visualização comum de cada área, com a aplicação de técnicas específicas para cada área clínica. Já para as imagens digitais de doenças de pele, são utilizados apenas filtros de realce de objetos, como a equalização do histograma. Com essas técnicas, é possível garantir que as imagens estejam prontas para serem processadas na próxima etapa da abordagem proposta.

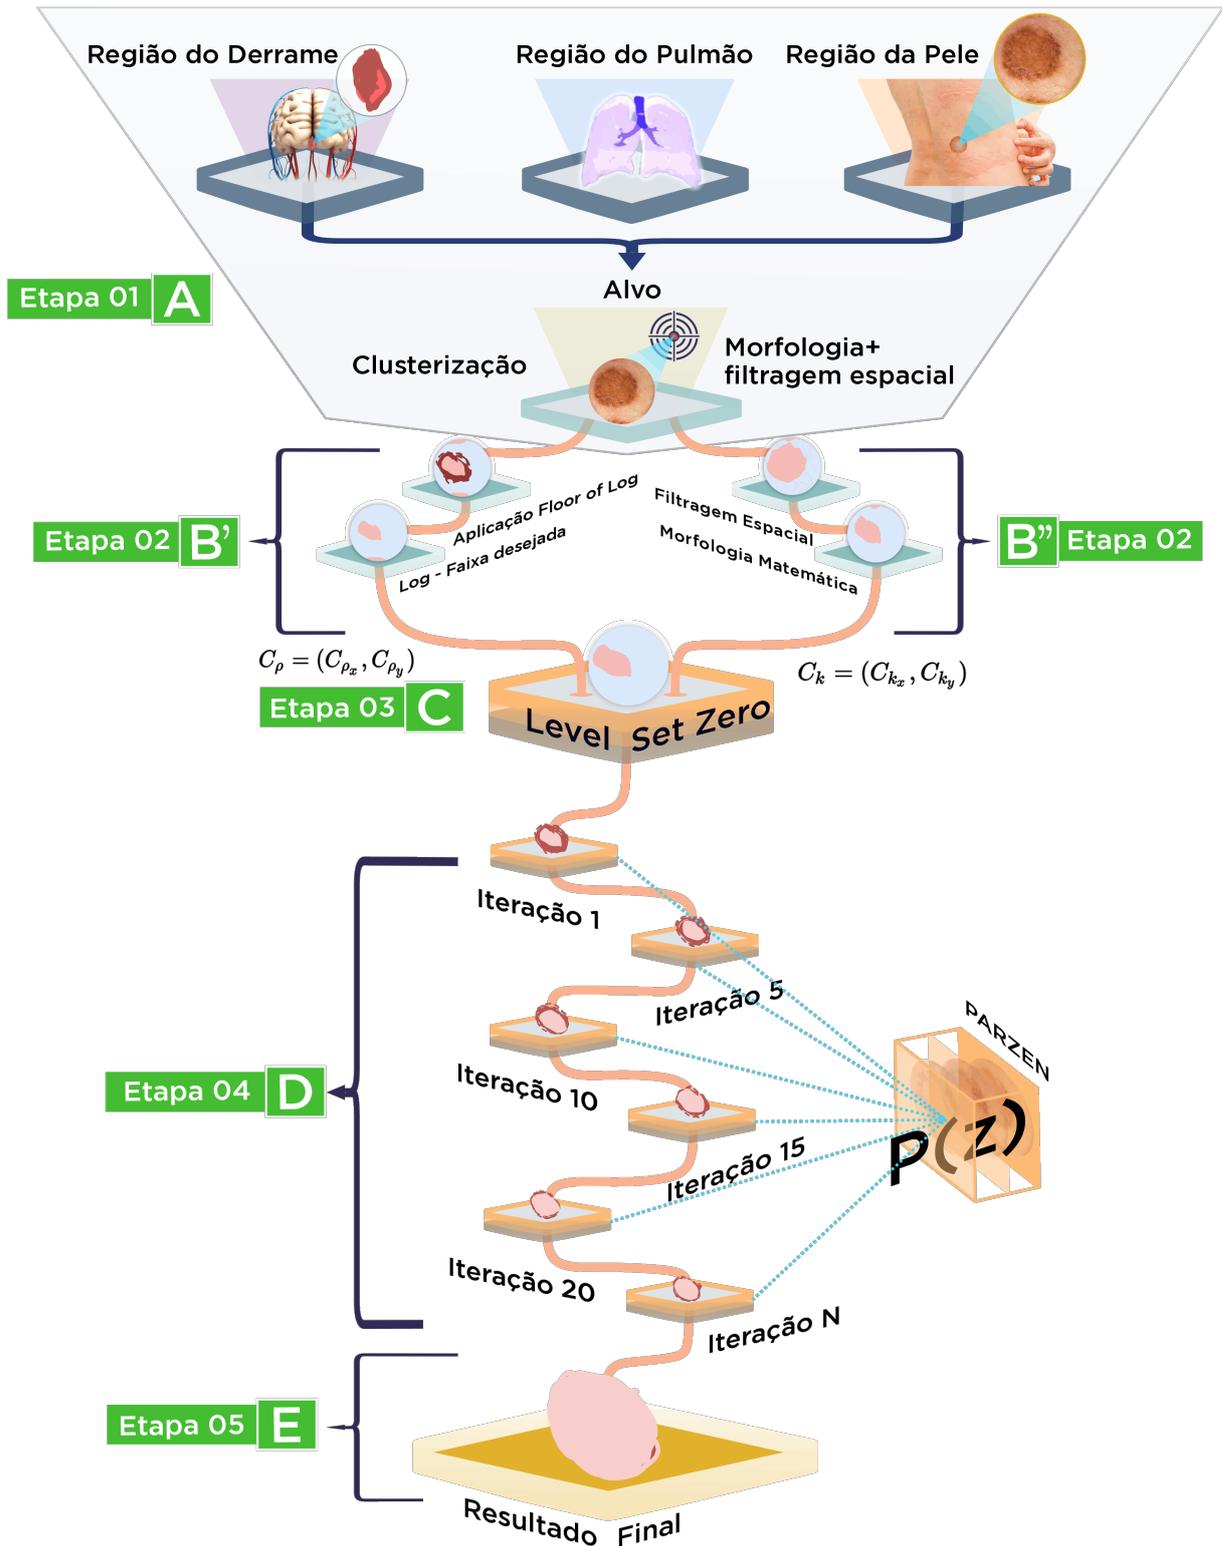


Figura 7 – Fluxograma da metodologia proposta. A) Correlação entre os três ambientes inseridos no método, a cor vermelha detecta a região de interesse; B') Inicialização via Processamento Digital de Imagem; B'') Inicialização via clustering; C) Definição do *level set zero* com base na similaridade encontrada entre os centróides das regiões; D) Envio da região definida de nível zero para o método *level set* baseado na janela de parzen onde a região é refinada com estimativas probabilísticas.

3.2 Etapa 02 - Inicialização da abordagem proposta

Antes de iniciar a segmentação das imagens, é crucial encontrar o *level set zero*, que é o ponto de partida para a delimitação da região de interesse. Na abordagem proposta, a Etapa 02 é dedicada exclusivamente a essa tarefa, envolvendo duas etapas paralelas descritas nas Subseções 3.2.1 e 3.2.2. Essas etapas visam definir a curva de inicialização, utilizando informações obtidas de diferentes fontes e que serão utilizadas na próxima etapa, como explicado na Subseção 3.2.3. Para tornar esse processo mais acessível, as Figuras 8, 9 e 10 ilustram a aplicação do método para inicializar o *level set* em imagens do crânio com AVC, imagens do tórax com pulmões e em lesões de pele, respectivamente. Dessa forma, a abordagem proposta permite encontrar com precisão e eficiência o ponto de partida para a segmentação, simplificando todo o processo subsequente de análise das imagens médicas.

3.2.1 Etapa 02 B' - Etapa de Clusterização: LBP + Floor of Log

A proposta de inicialização inclui uma etapa de clusterização que utiliza uma técnica combinada de LBP (Local Binary Pattern) (OJALA *et al.*, 1994) e FLog (Floor of Log) (PEIXOTO *et al.*, 2020a) para obter uma abordagem mais eficiente na inicialização do conjunto de níveis.

Para isso, a primeira etapa é aplicar o algoritmo LBP em uma imagem de entrada I com um código de 8 *bits* para cada *pixel*, gerando a nova imagem I_{LBP} . Essa imagem contém informações sobre as variações locais de intensidade da imagem original e ajuda a identificar as regiões de interesse. A imagem I_{LBP} é definida como:

$$I_{LBP} = LBP_{8,1}(I). \quad (3.1)$$

O valor de um código LBP para um *pixel* central c , de coordenada (x_c, y_c) , com amostragem de P vizinhos no raio R é dado por:

$$LBP_{P,R} = \sum_{p=0}^{P-1} s(g_p - g_c)2^p, \quad (3.2)$$

em que:

$$s(x) = \begin{cases} 1, & \text{se } x > 0 \\ 0, & \text{caso contrário} \end{cases}, \quad (3.3)$$

em que g_p e g_c são os níveis de cinza dos pontos de vizinhança p e central c , respectivamente. Na abordagem LBP, é comum utilizar valores padrão de P e R . Nesse caso, foi utilizado $P = 8$, que

é o número de vizinhos em torno do pixel central c , e $R = 1$, que é o raio da vizinhança circular em torno do pixel central c . Esses valores são comuns em várias aplicações de processamento de imagem, pois permitem detectar características de borda na imagem.

Para realçar os detalhes da textura na imagem de entrada I é realizada uma combinação com a imagem I_{LBP} , como mostrado na equação abaixo:

$$I_H = I + I_{LBP}. \quad (3.4)$$

Essa operação cria uma nova imagem I_H com realces de textura suficientes para a etapa de agrupamento. O agrupamento proposto é baseado em uma transformação linear das intensidades dos *pixels* da imagem de entrada. Essa transformação linear é definida por uma função logarítmica com base β . O valor de β é escolhido através de um processo de validação cruzada, que seleciona o melhor valor de β com base no nível aceitável de agrupamento para as amostras de teste (PEIXOTO *et al.*, 2020a).

Após a transformação linear, é aplicada uma operação de piso para agrupar os valores de intensidade que possuem textura semelhante. Essa operação de piso produz valores inteiros para o conjunto de intensidades. Este procedimento é denominado FLog, definido na equação abaixo:

$$g(x) = \lfloor \log_{\beta}(I_H + c) \rfloor, \quad (3.5)$$

em que a constante $c \in \mathbb{Z}^* +$ é adicionada para evitar inconsistências matemáticas.

3.2.2 Etapa 02 B'' - Filtragem Espacial + Morfologia Matemática

Para obter uma região de interesse binária a partir do conjunto de dados, serão aplicadas etapas de PDI. O resultado será uma imagem binária com uma região de interesse representada por um componente binário relacionado.

Primeiramente, será aplicada uma operação de média na imagem de entrada I_A , obtendo a imagem $I_{Média}$. Em seguida, será extraída a diferença entre a imagem I_A e a média calculada, resultando em I_{Diff_A} . Essa abordagem tem como vantagem a redistribuição dos *pixels* da imagem, tornando-os mais representativos do objeto de interesse. Após essa etapa, os *pixels* da imagem são convertidos em valores inteiros.

Como a imagem I_{Diff_A} é binária, uma função de componentes conectados será aplicada a ela para segmentar o fundo da imagem. Esse processo é vantajoso em termos

computacionais, já que o cálculo de regiões conectadas se restringe a apenas duas grandes regiões: os objetos de interesse e o fundo da imagem.

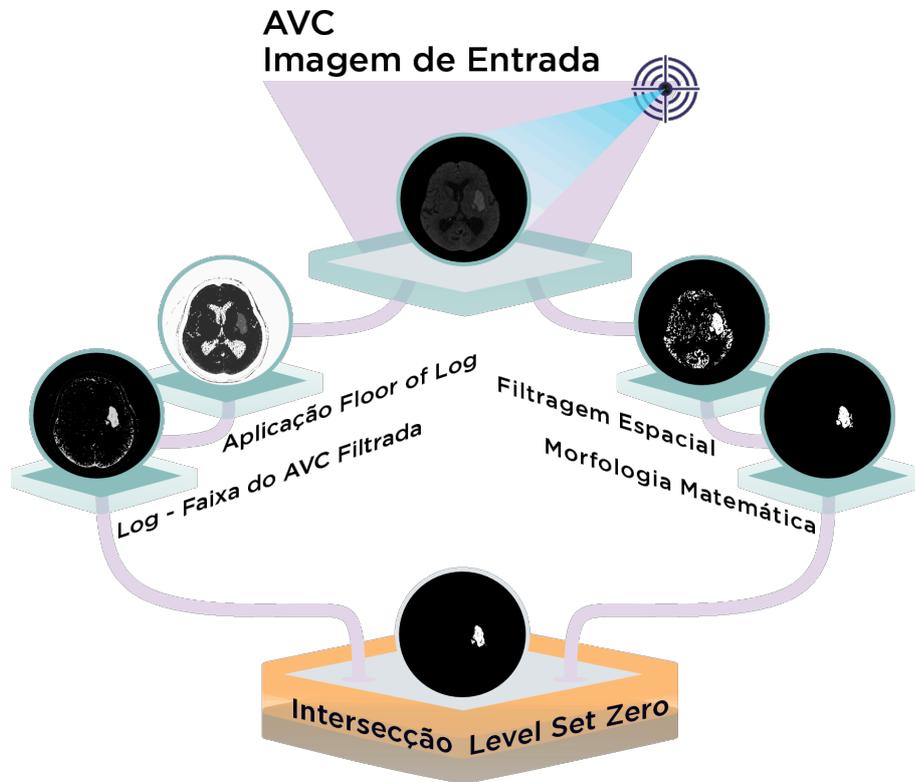


Figura 8 – Exemplo da inicialização proposta aplicada na detecção da região acometida pelo AVC para inicialização do *level set zero* em imagens de TC do crânio.

3.2.3 Etapa 03 - Intersecção entre B' e B''

Nesta etapa, é realizada a intersecção entre duas regiões: B' e B'' . O objetivo é encontrar a maior região conectada presente na intersecção, que melhor representa a região de interesse do problema.

A partir dessa intersecção, é criada uma nova imagem binária I_p , que representa a região de interesse identificada pelo método proposto. Essa imagem é o *level set zero*, ou seja, a fronteira que separa a região de interesse do restante da imagem.

Essa etapa é importante para garantir que a região de interesse seja a mais significativa para a aplicação em questão e, assim, fornecer uma inicialização mais precisa para os algoritmos que trabalham com a região de interesse.

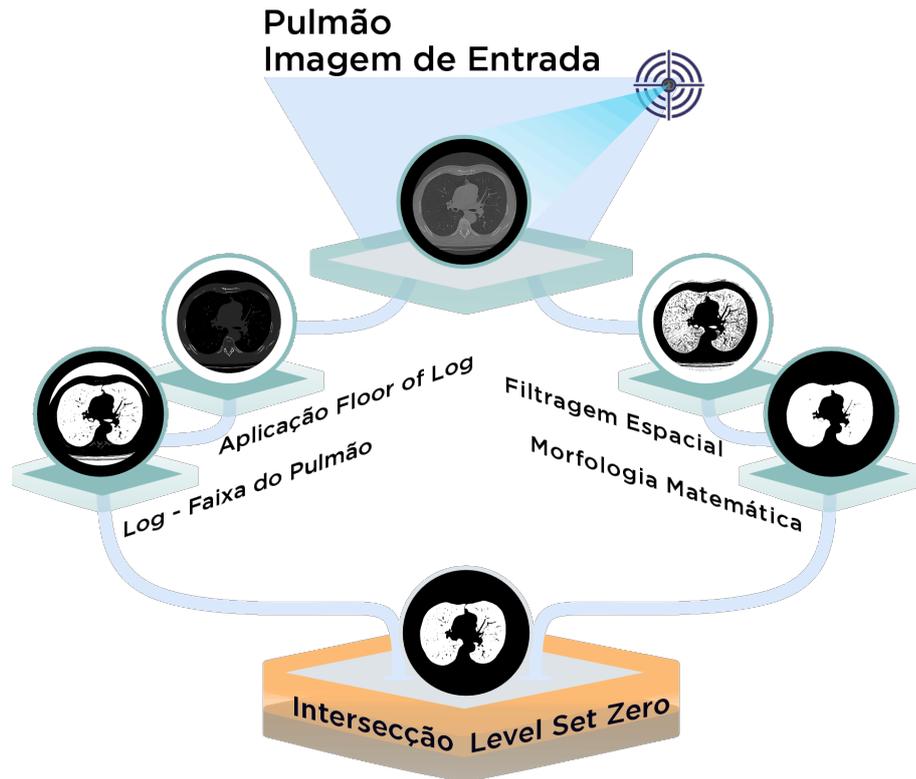


Figura 9 – Exemplo da inicialização proposta aplicada na detecção da região dos pulmões para inicialização do *level set zero* em imagens de TC do tórax.

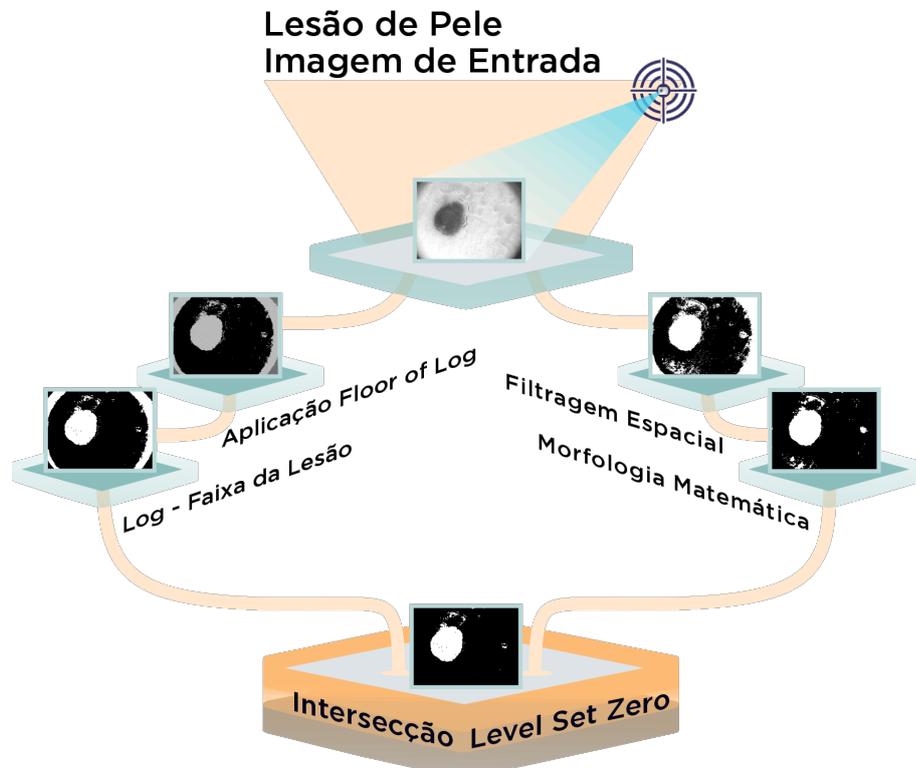


Figura 10 – Exemplo da inicialização proposta aplicada na detecção da região acometida pelas lesões de pele para inicialização do *level set zero* em imagens digitais.

3.3 Etapa 04 - *Level set* usando uma estimação não paramétrica com base na janela de parzen

Após determinar o *level set* zero, a evolução do *level set* neste trabalho usa uma estimativa não paramétrica baseada na janela de parzen. Assim, a janela de parzen adota uma matriz de covariância diagonal n -dimensional $\Lambda = \sigma^2 I_d$, onde I é uma matriz identidade. As características individuais também são consideradas mutuamente correlacionadas e têm a mesma variação σ^2 .

Para $d = 3$, a matrix diagonal é $\Lambda = \sigma^2 I_d = \begin{bmatrix} \sigma^2 & 0 & 0 \\ 0 & \sigma^2 & 0 \\ 0 & 0 & \sigma^2 \end{bmatrix}$. Então o $p(z)$ final, da

Equação 2.7, usando o *kernel* da Equação 2.8 pode ser expresso como (BISHOP, 2006)

$$p(z) = \frac{1}{k} \sum_{i=1}^k \frac{1}{(2\pi)^{d/2} h^d} \exp\left(-\frac{1}{2h^2} \|z_i - z\|^2\right), \quad (3.7)$$

em que h representa o desvio padrão de σ dos componentes gaussianos e $\|\cdot\|^2$ representa a distância euclidiana. Neste trabalho, foi utilizado o valor de $h = 7$ obtido empiricamente.

Para um método *level set* com duas fases, ou seja, para a binarização de uma imagem, a solução geral da velocidade de propagação F_{prop} é dada por:

$$F_{prop} = F_1(\vec{\eta}) + F_2(-\vec{\eta}), \quad (3.8)$$

em que os termos F_1 e F_2 são os componentes da velocidade de propagação.

Na abordagem proposta, um modelo de verossimilhança (MITICHE; AYED, 2010) é usado para calcular o termo de propagação F_{prop} no qual os componentes F_1 e F_2 são estimados usando a janela de parzen. Para obter esses componentes, dois conjuntos de *pixels*, ou seja, cada *pixel* z da imagem é definido como um vetor de dimensão d , um dos quais pertence à região interna de a curva, dada por $Z_1 = \{z_i\}_{i=1}^n$ e o outro conjunto pertencente à região externa da curva, dado por $Z_2 = \{z_i\}_{i=1}^n$, são usados, e onde n é o número de *pixels*. Para gerar Z_1 e Z_2 , os *pixels* são obtidos aleatoriamente de suas respectivas regiões. Os *pixels* desses dois conjuntos formam duas janelas $h \times h$ que é o tamanho da janela usada no método de parzen. Cada *pixel* das regiões Z_1 e Z_2 é um vetor com 3 atributos, a saber, intensidade de pixel I , média μ e variância σ^2 .

Finalmente, a velocidade de propagação com base na estimativa de parzen é definida como:

$$F_{prop} = p(I, \mu_1, \sigma_1^2) \vec{\eta} - p(I, \mu_2, \sigma_2^2) \vec{\eta}, \quad (3.9)$$

em que os índices 1 e 2 denotam as regiões internas e externas à curva $\vec{\phi}$, respectivamente.

Neste trabalho foi utilizado o método *level set* proposto por Braga (2016) que utiliza filtros da mediana e operadores de morfologia matemática detalhada na Seção 2.3. Este algoritmo *level set* utiliza o filtro da mediana, que consiste de um filtro não paramétrico, para regularizar a curva ao invés de utilizar a curvatura \mathcal{K} apresentada na Equação 2.3.

Para apresentar a evolução da abordagem proposta, as Figuras 11, 12 e 13 mostram o desenvolvimento da curva usando o *FLog Parzen Level Set* em cada um dos conjuntos de dados utilizados na validação da abordagem proposta. O processo de iteração começa com a inicialização do contorno ativo na região de interesse da imagem e a aplicação do método de contorno ativo *level set* com a estimativa não paramétrica baseada na janela de parzen. A cada iteração, o contorno ativo é atualizado, movendo-se para minimizar a energia do contorno, até que a convergência seja alcançada e a região de interesse seja completamente segmentada. Esse processo é repetido para todas as amostras do *dataset*. Na legenda de cada imagem, é possível observar a evolução da curva de segmentação representada pela parte vermelha, bem como o número de iterações do contorno ativo, indicado por "C".

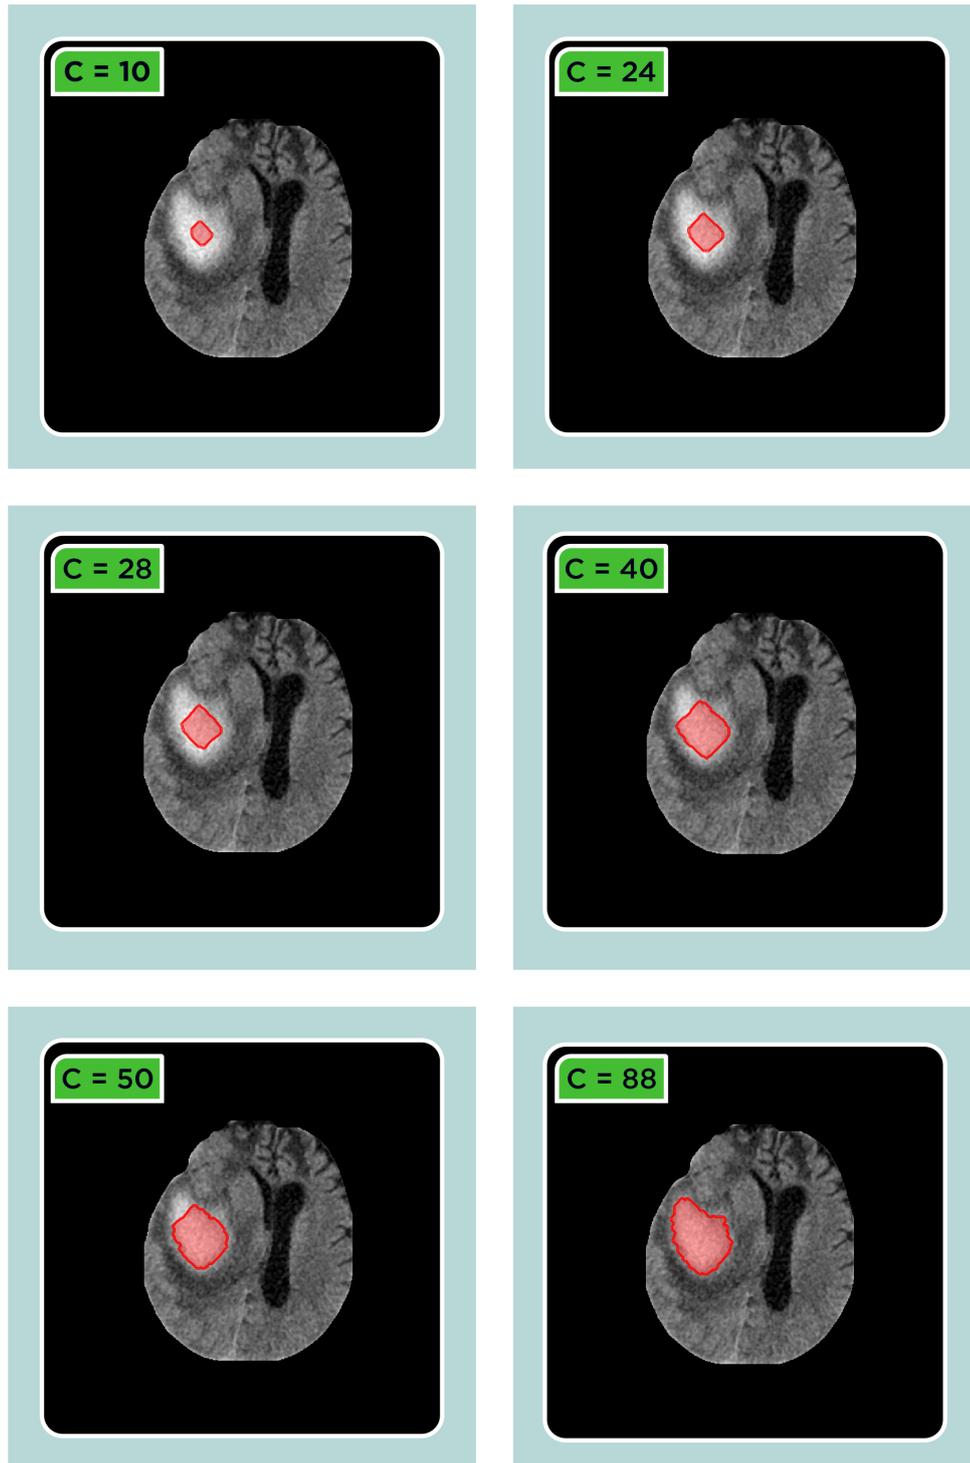


Figura 11 – Processo de iteração do método proposto em amostras do *dataset* de AVC. Na legenda, o "C" significa o número de iterações do contorno ativo.

3.4 Base de dados

Para realizar a pesquisa, utilizei três conjuntos de dados de imagens médicas privadas. O primeiro conjunto de dados é composto por 100 imagens de seções axiais de acidente vascular cerebral hemorrágico. Esses exames foram obtidos de diferentes pacientes atendidos pelo Hospi-

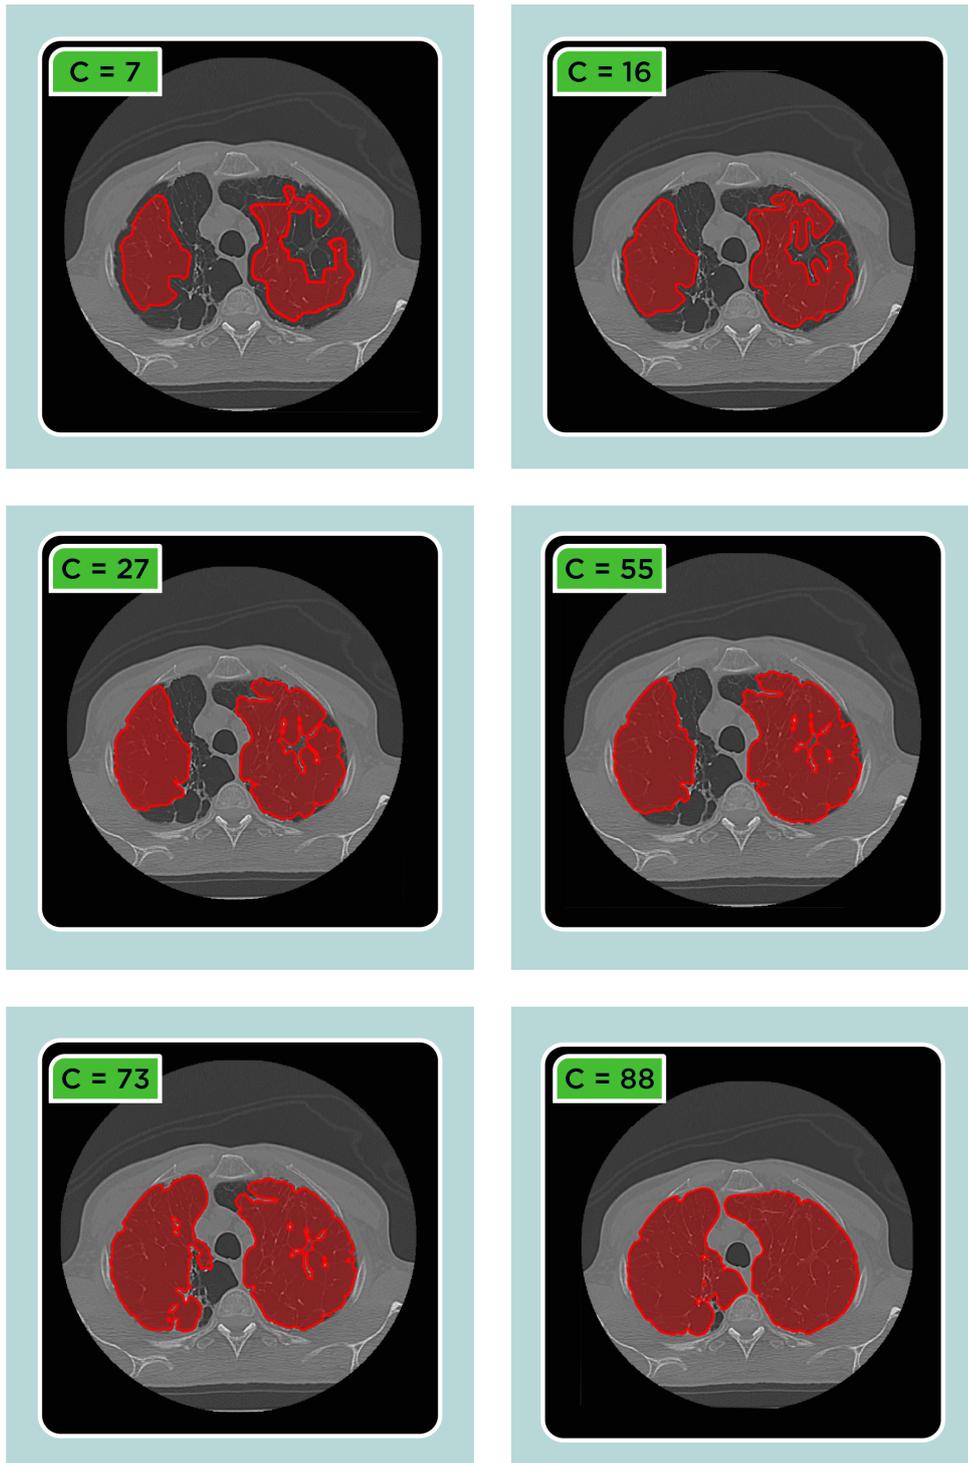


Figura 12 – Processo de iteração do método proposto em amostras do *dataset* de pulmão. Na legenda, o "C" significa o número de iterações do contorno ativo.

tal do Coração de Fortaleza, Brasil, e realizados com o aparelho de tomografia computadorizada (TC) GE MEDICAL SYSTEM optima CT660. Cada exame possui uma espessura de corte e campo de visão equivalentes a 0,7 mm e 230 mm, respectivamente. As imagens resultantes têm um tamanho de 512×512 *pixels* no formato DICOM (Digital Imaging and Communications in Medicine) e um padrão de intensidade de *pixel* de 16 *bits*.

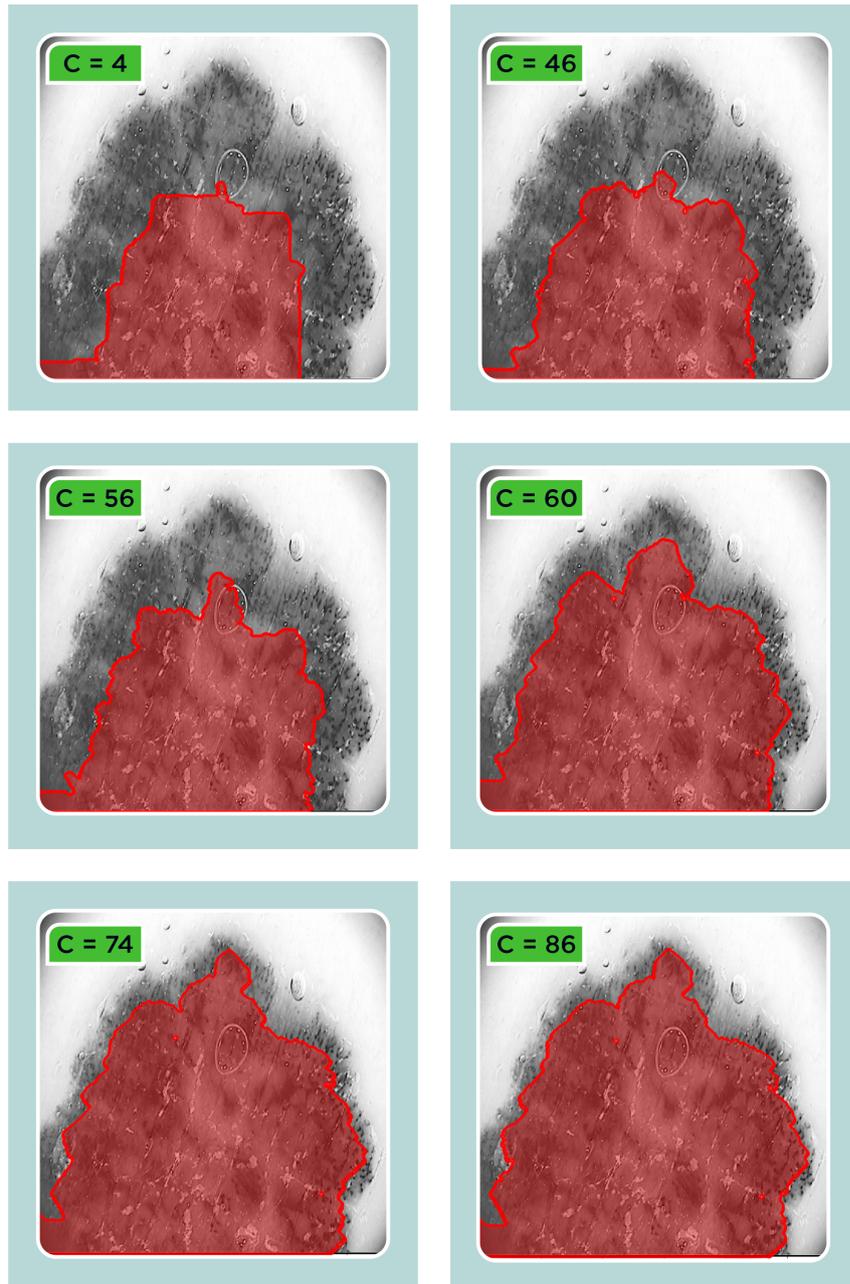


Figura 13 – Processo de iteração do método proposto em amostras do *dataset* de pele. Na legenda, o "C" significa o número de iterações do contorno ativo.

O segundo conjunto de dados é composto por 39 imagens de tomografia computadorizada do pulmão adquiridas em parceria com o Hospital Walter Cantídio da Universidade Federal do Ceará (UFC), Brasil, e aprovadas pelo Comitê de Ética em Pesquisa. Esse conjunto de exames possui um total de 13.000 cortes com tamanho de 512×512 *pixels* e intensidade de *pixel* no padrão de 16 *bits*. Das 13.000 fatias produzidas no formato DICOM, 1.265 foram segmentadas manualmente por um especialista para avaliação dos métodos.

Por fim, o terceiro conjunto de dados é composto por 200 imagens dermatoscópicas de lesões de pele, comumente chamado de PH2. Essas imagens foram coletadas de exames

microscópicos de pele que foram ampliados em 20 vezes o tamanho original. A coleção de imagens foi disponibilizada pelo Serviço de Dermatologia do Hospital Pedro Hispano, em Portugal. Cada imagem tem intensidades de *pixel* padrão de 8 *bits* e dimensões de 768 x 560 *pixels*.

Para ilustrar a diversidade e as características dos conjuntos de dados utilizados neste trabalho, as Figuras 14, 15 e 16 apresentam seis imagens selecionadas aleatoriamente de cada conjunto de dados. A escolha dessas imagens levou em conta a representatividade da diversidade das imagens em termos de tamanho, forma, intensidade e contraste. Cada imagem apresenta desafios únicos para a segmentação, evidenciando a importância de uma abordagem robusta e precisa para lidar com a variedade de tipos de imagens. É importante mencionar que os conjuntos de dados utilizados são privados, o que ressalta a relevância da pesquisa realizada nesta tese.

A implementação da metodologia da tese foi feita em um computador com Ubuntu 16.04, processador Intel Xeon e 8GB de RAM. A linguagem de programação escolhida foi o Python 3.6, que é uma linguagem muito utilizada na área de ciência de dados. Para construir o método, desenvolvemos algumas funções próprias, mas a maior parte do código foi baseado em bibliotecas Python amplamente utilizadas, como OpenCV v4.1.0, numpy v1.19.5 e matplotlib v3.3.3. Essas bibliotecas forneceram todas as ferramentas necessárias para lidar com os desafios técnicos encontrados durante a pesquisa.

Ainda não disponibilizamos o método publicamente, mas pretendemos fazê-lo em um repositório no GitHub em breve.

3.4.1 Análise de Desempenho

Com o intuito de fornecer uma avaliação quantitativa do resultado da segmentação do AVC hemorrágico, DPOC e câncer de pele, utilizamos métricas comumente adotadas na literatura para avaliar métodos de segmentação. Tais métricas mensuram a discrepância e/ou semelhança entre a região segmentada e a região da imagem de referência. A região de referência é delineada manualmente por um médico especialista e tomada como padrão ouro (*ground truth*). A avaliação é realizada usando métricas com base na quantidade de *pixels* que tenham sido corretamente e/ou incorretamente atribuídos a uma região da imagem (GARCIA *et al.*, 2015). Em uma imagem com apenas duas regiões, a segmentação pode ser vista como um processo de classificação (PONT-TUSET; MARQUES, 2013) no qual cada *pixel* é rotulado como 0 ou 1, em

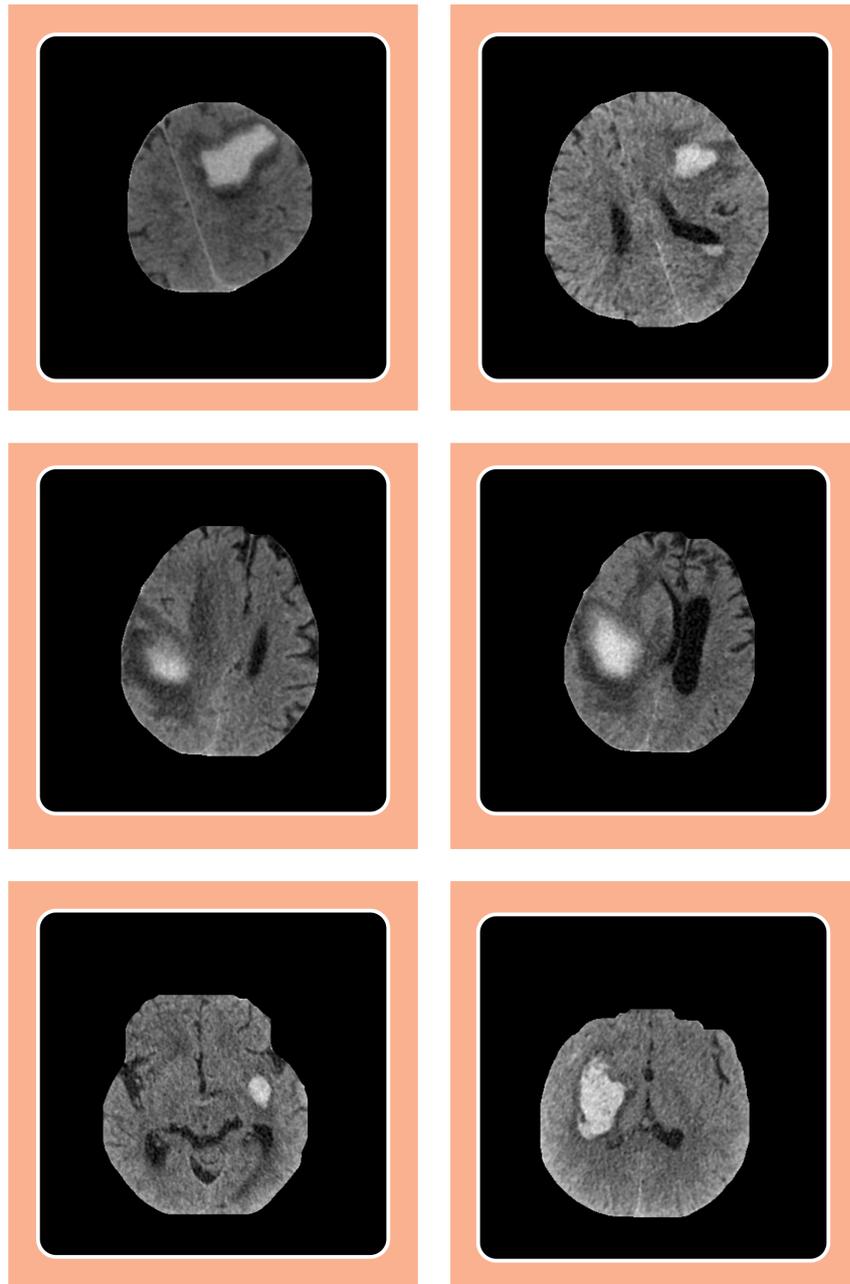


Figura 14 – Exemplos de amostras do *dataset* de AVC usadas para avaliar a abordagem proposta neste trabalho. As imagens destacam características diversas, como tamanho, forma, intensidade e contraste, para fornecer uma visão geral da complexidade do conjunto de dados. Cada imagem apresenta desafios únicos para a segmentação, sendo que algumas delas contêm hemorragias em diferentes partes do cérebro, enquanto outras têm um formato mais irregular.

que 1 significa que o *pixel* pertence à região de interesse (*ROI*) e 0 significa a região de fundo (*RF*). A região alvo representa a área de interesse que é nomeada como classe positiva, enquanto que a região do fundo é chamada classe negativa.

Para o resultado de um processo de segmentação, espera-se que uma região segmentada (*RS*) por um método computacional seja o mais semelhante possível à *ROI*. A relação entre

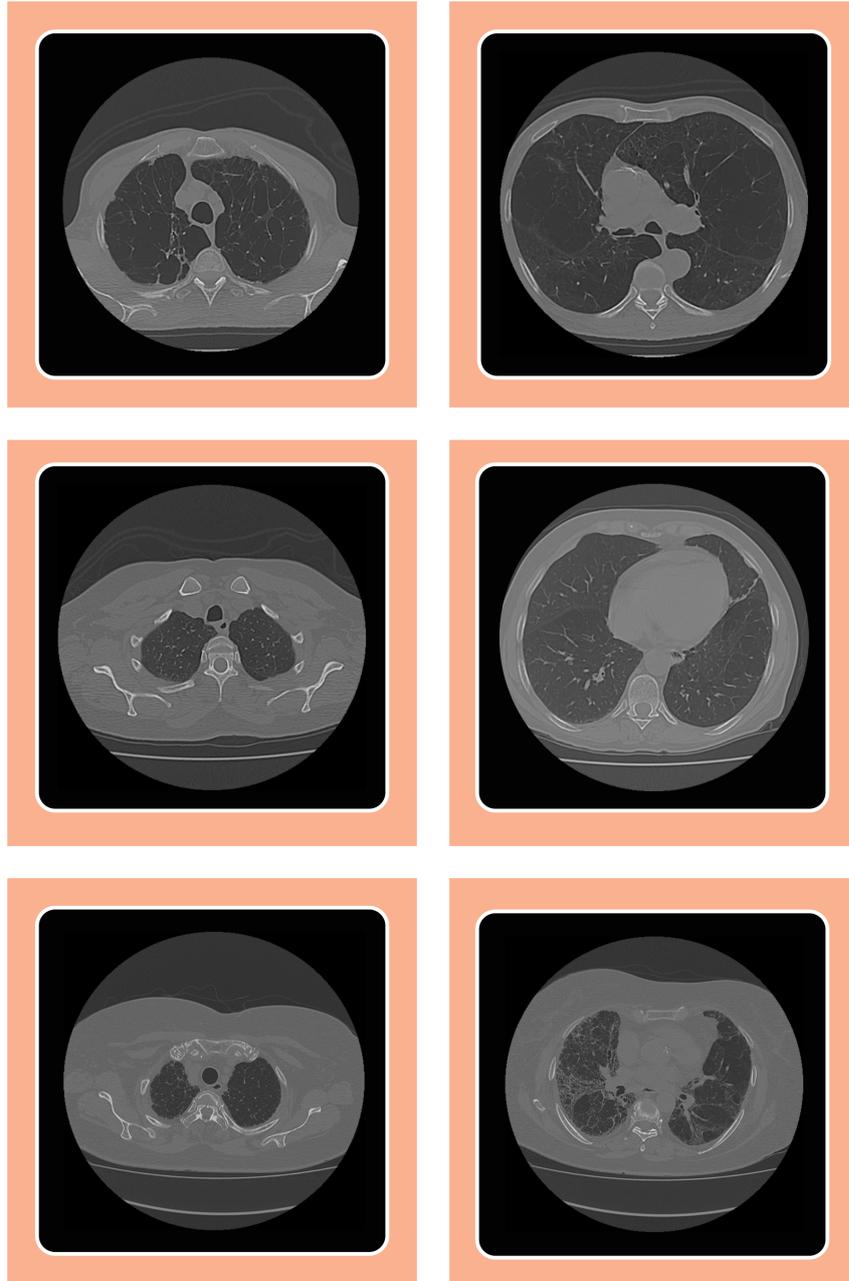


Figura 15 – Exemplos de amostras do *dataset* de pulmão usadas para avaliar a abordagem proposta neste trabalho. As imagens destacam características diversas, como tamanho, forma, intensidade e contraste, para fornecer uma visão geral da complexidade do conjunto de dados.

estas duas regiões pode ser expressa em uma matriz de confusão, como mostra a Tabela 1, em que todas essas medidas estão em função das medidas de verdadeiro positivo (*VP*), falso positivo (*FP*), verdadeiro negativo (*VN*) e falso negativo (*FN*) (METZ, 1978).

A Figura 17 ilustra a representação gráfica de *VP*, *FP*, *VN* e *FN*, em que a imagem de fundo é composta por $VN + FP$ e a região de interesse é a soma de $VP + FN$, em que:

- *VP* é igual ao número de *pixels* que aparece tanto na área da lesão segmentada manualmente como na área da lesão segmentada pelo método computacional.



Figura 16 – Exemplos de amostras do *dataset* de pele usadas para avaliar a abordagem proposta neste trabalho. As imagens destacam características diversas, como tamanho, forma, intensidade e contraste, para fornecer uma visão geral da complexidade do conjunto de dados.

- *FP* é igual ao número de *pixels* ausente na área da lesão segmentada manualmente, mas aparece na área da lesão segmentada pelo método computacional.
- *VN* é igual ao número de *pixels* ausente tanto na área da lesão segmentada manualmente como na área da lesão segmentada pelo método computacional.
- *FN* é igual ao número de *pixels* aparece na área da lesão segmentada manualmente, mas está ausente na área da lesão pelo método computacional.

A seguir, são detalhadas as métricas utilizadas para avaliação do resultados alcança-

Tabela 1 – Representação do modelo de matriz de confusão 2x2 utilizada.

	Lesão (Segmentado)	Fundo (Segmentado)
Lesão (Real)	VP	FN
Fundo (Real)	FP	VN

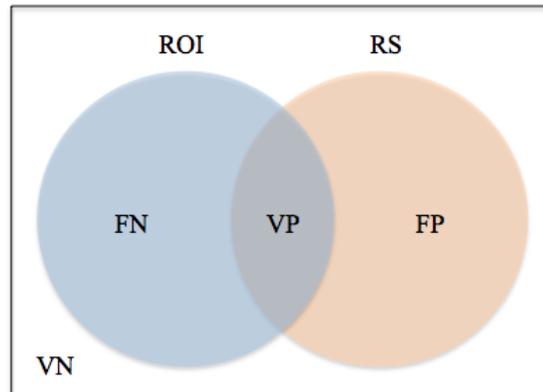


Figura 17 – Regiões onde *VP*, *FP*, *VN* e *FN* são computadas. O círculo ROI representa a região de referência (padrão ouro). O círculo RS representa a região segmentada por um método computacional (Adaptado de Garcia *et al.* (2015)).

dos, verificando o desempenho da abordagem proposta neste trabalho.

3.4.1.1 Métricas Quantitativas

Para auxiliar na avaliação e discussão dos resultados, foram adotadas as métricas de Acurácia (Acc), Precisão (Prec), Sensibilidade (Sen), Especificidade (Esp) e Coeficiente de Correlação de Matthews (MCC), que são amplamente utilizadas na avaliação de algoritmos de segmentação de imagens médicas. Essas métricas são calculadas a partir dos valores de verdadeiro positivo (TP), falso positivo (FP), verdadeiro negativo (TN) e falso negativo (FN) já apresentados anteriormente. Elas fornecem uma medida quantitativa da qualidade da segmentação em comparação com o padrão ouro, que é a segmentação de referência feita por um especialista (MÜLLER *et al.*, 2022). O uso dessas métricas permite uma avaliação objetiva e comparativa da eficácia de diferentes algoritmos de segmentação em imagens médicas. Cada uma dessas medidas foi utilizada para o cálculo das métricas de avaliação que serão descritas a seguir.

A Acurácia é uma métrica de classificação que analisa a proporção de previsões corretas em relação ao total de previsões. Essa medida de avaliação é simples de ser interpretada, mas é suscetível a conjuntos de dados desequilibrados, onde uma classe pode ser muito mais prevalente do que a outra. Em termos de segmentação, a acurácia é definida como o número total de pixels corretamente segmentados dividido pelo número total de pixels no conjunto. Por outro lado, a Precisão mede a proporção de pixels corretamente segmentados em relação ao total de pixels segmentados pelo modelo. Uma alta precisão significa que o método de segmentação está acertando com mais frequência do que errando (TAHA; HANBURY, 2015). A fórmula da acurácia:

$$Accuracy = \frac{TP + TN}{TP + FN + FP + TN}. \quad (3.10)$$

A Precisão, também conhecida como valor preditivo positivo, é uma métrica que calcula a proporção de verdadeiros positivos em relação a todos os valores positivos previstos pelo modelo. Essa medida indica a habilidade do modelo em identificar corretamente os pixels que pertencem à classe de interesse em relação aos pixels que foram erroneamente classificados como pertencentes à classe de interesse. Em outras palavras, a Precisão mede a capacidade do modelo em evitar falsos positivos, e é dada por:

$$Prec = \frac{TP}{TP + FP}. \quad (3.11)$$

A Sensibilidade calcula a proporção de valores verdadeiramente positivos que foram corretamente identificados como positivos em relação a todos os valores positivos presentes na imagem. Em outras palavras, a Sensibilidade calcula a probabilidade entre os valores verdadeiramente positivos e os valores falsos que foram erroneamente identificados como negativos, como sendo:

$$Sen = \frac{TP}{TP + FN}. \quad (3.12)$$

A Especificidade mede a proporção de valores verdadeiramente negativos, com os valores falsos positivos definidos como pixels que deveriam ter sido classificados como negativos, mas foram erroneamente classificados como positivos, como:

$$Spec = \frac{TN}{TN + FP}. \quad (3.13)$$

A Correlação do Coeficiente de Matthews é uma métrica amplamente utilizada em segmentação de imagens médicas, que permite avaliar a precisão e eficácia de um método de

segmentação, mesmo quando há uma diferença significativa entre as classes de amostras. Essa diferença pode ser causada, por exemplo, pela presença de *pixels* de fundo em grande quantidade em comparação com os *pixels* de objeto na imagem. A MCC varia de -1 a 1, sendo que o valor 1 representa uma segmentação perfeita, 0 indica uma segmentação aleatória e -1 indica uma segmentação inversa, sendo dada por:

$$MCC = \frac{(TP * TN - FP * FN)}{\sqrt{(TP + FP) * (TP + FN) * (TN + FP) * (TN + FN)}}. \quad (3.14)$$

3.4.1.2 Métricas de Similaridade

As medidas de similaridade são parâmetros objetivos que permitem avaliar o nível de semelhança entre duas ou mais amostras. Para avaliar a qualidade da segmentação, foram considerados três índices de similaridade: Distância de Hausdorff (HD), Coeficiente Dice (Dice) e Índice de Jaccard (Jac).

A distância de Hausdorff (*HD*) calcula a distância da extensão em que cada ponto de um conjunto está mais próximo ao ponto de um conjunto de imagens e vice-versa. Essa métrica pode ser utilizada para determinar o grau de correspondência entre dois objetos que se sobrepõem um ao outro (BEAUCHEMIN *et al.*, 1998).

Na literatura, a *HD* é definida como:

$$H(A, B) = \max \{h(A, B), h(B, A)\}, \quad (3.15)$$

$$h(A, B) = \max_{a \in A} \left\{ \min_{b \in B} \{d(a, b)\} \right\}, \quad (3.16)$$

$$h(B, A) = \max_{b \in B} \left\{ \min_{a \in A} \{d(b, a)\} \right\}. \quad (3.17)$$

Os conjuntos $A = a_1, a_2, \dots, a_n$ e $B = b_1, b_2, \dots, b_n$ representam dois conjuntos finitos de pontos, onde d é uma distância entre dois pontos em espaços matriciais. A representação dessas distâncias pode indicar de forma simplificada como se pertence a um elemento de A e calculam-se as distâncias a todos os elementos de B . Desta forma, é registrado o menor valor dentre os elementos calculados, em seguida, repetindo o passo anterior para todos os demais elementos de pertencentes ao conjunto de A , determinando assim o maior valor registrado.

Desta forma, entende-se que, $h(A, B)$ é a maior das menores distâncias que separam os pontos de A de qualquer ponto de B . Assim, $h(B, A)$ será determinada da mesma forma de forma inversa e assim calculando a distância.

Essa medida é muito utilizada em segmentação de imagens médicas para avaliar o quão bem uma região segmentada se aproxima da região verdadeira, que é definida por um especialista. Por exemplo, em um problema de segmentação de tumor cerebral, a região verdadeira é definida por um especialista que analisou a imagem e identificou a área exata do tumor. A segmentação produzida por um algoritmo é comparada com a região verdadeira utilizando a distância de Hausdorff, que mede a maior distância entre um ponto da segmentação e o ponto mais próximo da região verdadeira, e vice-versa. Quanto menor a distância de Hausdorff, melhor a segmentação.

O coeficiente de Dice (Dice) é um índice que mede a similaridade entre duas regiões segmentadas, uma obtida de forma automática e outra manualmente definida como padrão de referência. A fórmula para calcular o coeficiente de Dice é definido como:

$$Dice = 2 \times \frac{|S_m \cap S_t|}{|A_k| + |A_l|}. \quad (3.18)$$

Na Equação 3.18, S_m representa a região segmentada automaticamente, e S_t representa a região segmentada manualmente pelo especialista. O valor do coeficiente de Dice varia de 0 a 1, onde 0 indica que não há sobreposição entre as duas regiões, e 1 indica uma sobreposição perfeita entre as duas regiões. Quanto maior o valor do coeficiente de Dice, maior a similaridade entre a região segmentada automaticamente e a região segmentada pelo especialista, também conhecida como *ground truth* (QIAN *et al.*, 2013). Em outras palavras, o coeficiente de Dice é uma medida de quão bem o método de segmentação automática se compara com o padrão de referência manual, e quanto maior o valor do coeficiente, mais precisas são as segmentações automáticas.

Índice de Jaccard - Semelhante ao coeficiente de Dice, é uma métrica para comparar a similaridade entre um conjunto finito de amostras (BERTELS *et al.*, 2019). O Índice de Jaccard pode ser dado como:

$$Jac = \frac{TP}{TP + FP + FN}. \quad (3.19)$$

Na Equação 3.19, TP é o número de verdadeiros positivos, FP é o número de falsos positivos e FN é o número de falsos negativos. Um valor de Jac igual a 1 indica que as duas amostras são idênticas, enquanto um valor igual a 0 indica que as duas amostras não têm nenhuma região em comum. O Jac pode variar entre 0 e 1, onde valores mais próximos de 1 indicam maior sobreposição e, portanto, maior similaridade entre as amostras.

A principal diferença entre o coeficiente de Dice e o Índice de Jaccard é a forma como eles medem a sobreposição entre as regiões. O Dice é mais sensível a pequenas diferenças na sobreposição, enquanto o Jac é mais sensível a grandes diferenças. Ambas as métricas são importantes na avaliação da qualidade da segmentação, e podem ser utilizadas em conjunto para uma avaliação mais completa (BERTELS *et al.*, 2019).

3.5 Conclusão do Capítulo

Neste capítulo, apresentamos uma proposta de inicialização do ponto de semente na região de interesse, utilizando a interseção do Floor of Log (FLog) e métodos de filtragem espacial e morfologia matemática para encontrar o *level set* zero em diferentes bases de imagens com o objetivo de auxiliar no diagnóstico médico. Em seguida, destacamos a principal contribuição desta tese, que é o cálculo da função de densidade de probabilidade do *level set* rápido por meio de uma estimação não paramétrica baseada na janela de Parzen. Apresentamos exemplos das etapas da abordagem proposta, desde a inicialização da curva até a sua estabilização. Além disso, detalhamos as etapas da abordagem proposta e suas contribuições para a área, bem como as bases de imagens utilizadas, incluindo imagens de TC do crânio, do tórax e imagens digitais de lesões de pele. Por fim, descrevemos as métricas de avaliação adotadas nesta tese, que utilizam os resultados obtidos por um médico especialista como referência. No próximo capítulo, apresentaremos os resultados experimentais deste trabalho, além de uma análise comparativa entre a abordagem proposta e outros métodos de segmentação em imagens médicas existentes na literatura.

4 EXPERIMENTOS, RESULTADOS E DISCUSSÕES

Neste capítulo, apresentamos os resultados experimentais obtidos pelas abordagens de segmentação propostas no Capítulo 3 em imagens de AVC, pulmão e pele. Todos os experimentos foram realizados em um processador Intel Core i5 com 3,2 GHz e 8 GB RAM, utilizando a linguagem Python para o método proposto.

Nas Seções 4.1, 4.2 e 4.3, discutimos os resultados alcançados pelo método proposto e as comparações com os trabalhos mais relevantes encontrados na literatura, a partir do processamento dos *datasets* de AVC, pulmão e pele, respectivamente. Para avaliar o desempenho do método proposto, utilizamos métricas de avaliação como sensibilidade, especificidade, precisão, índice de Jaccard e coeficiente de Dice, que nos permitiram avaliar a qualidade da segmentação em termos de cobertura e precisão.

Os resultados das três bases de dados foram analisados separadamente, com a criação de diversas tabelas para facilitar a visualização dos resultados das diferentes doenças. Essa abordagem permitiu uma análise mais detalhada dos resultados, considerando as características específicas de cada conjunto de dados e as particularidades de cada doença. Além disso, comparamos nossos resultados com trabalhos relevantes encontrados na literatura, a fim de demonstrar a eficácia do método proposto em relação a outras abordagens disponíveis.

No geral, os resultados obtidos mostraram que nosso método proposto foi capaz de alcançar uma segmentação de alta qualidade em imagens de AVC, pulmão e pele, superando as abordagens mais significativas da literatura em termos de precisão e cobertura. Esses resultados são promissores e demonstram o potencial do método proposto para ser utilizado na prática clínica para auxiliar no diagnóstico e tratamento dessas doenças.

4.1 Acidente Vascular Cerebral (AVC)

Esta subseção apresenta os resultados e comparações obtidos com o conjunto de dados de acidente vascular cerebral (AVC), utilizando seis métricas diferentes: precisão (Prec), sensibilidade (Sen), especificidade (Esp), coeficiente de correlação de Matthews (MCC), coeficiente de similaridade de dados (Dice) e Índice de Jaccard (Jac).

Ao analisar a Tabela 2, é possível observar que o método proposto, FPLS, obteve os melhores resultados em precisão e especificidade, com valores de 99,11% e 99,94%, respectivamente, o que indica uma alta efetividade em segmentar corretamente a região de interesse nas

imagens de AVC, com maior robustez em relação aos erros de falso positivo e falso negativo.

Entretanto, a sensibilidade do FPLS apresentou um valor maior em comparação a outros métodos, como o (REBOUÇAS *et al.*, 2017), que obteve uma sensibilidade de 99,96%. Isso indica que o método FPLS pode estar deixando de detectar alguns *pixels* que estão presentes na lesão da imagem segmentada manualmente, resultando em um número maior de falsos negativos.

Embora a sensibilidade menor possa indicar que o método FPLS está deixando de detectar alguns *pixels* que estão presentes na lesão, é importante ressaltar que essa técnica ainda apresenta um alto valor de precisão, de 99,11%. Isso significa que, embora possa haver alguns falsos negativos, as regiões identificadas como lesões são muito precisas e confiáveis. Em um auxílio ao diagnóstico médico, é preferível um método que apresente um menor número de falsos positivos, ou seja, *pixels* identificados como lesão, mas que na verdade não são, do que um menor número de falsos negativos, pois os falsos positivos podem levar a procedimentos desnecessários ou invasivos, enquanto os falsos negativos podem deixar lesões não detectadas e não tratadas.

Em resumo, embora a sensibilidade do método FPLS seja menor em comparação a outros métodos, seus resultados em precisão e especificidade são bem maiores, o que o torna uma opção viável e eficaz para a segmentação de lesões em imagens de AVC.

Tabela 2 – Resultados de Precisão (Prec), Sensibilidade (Sen) e Especificidade (Esp) com seus respectivos desvios padrão para a base de dados de AVC. Os valores destacados em negrito correspondem ao método proposto e os melhores resultados estão destacados em verde.

Métodos	Prec(%)	Sen(%)	Esp(%)
FPLS	99,11 ± 00,09	83,34 ± 08,72	99,94 ± 00,09
(BRAGA <i>et al.</i> , 2021)	97,64 ± 16,14	78,70 ± 09,40	99,92 ± 00,03
(BRAGA <i>et al.</i> , 2017)	50,01 ± 27,76	99,34 ± 01,23	98,50 ± 00,94
(REBOUÇAS <i>et al.</i> , 2017)	99,75 ± 00,25	99,96 ± 00,05	83,03 ± 11,13
(ROUHI <i>et al.</i> , 2015)	99,00 ± 04,36	99,66 ± 00,23	92,84 ± 21,88
(KÖRBES; LOTUFO, 2010)	99,84 ± 00,19	99,85 ± 00,11	87,32 ± 13,38

A Tabela 3 mostra a avaliação do desempenho do método proposto, FPLS, em relação a outras abordagens, considerando as métricas de similaridade. O método proposto, FPLS, apresentou os melhores resultados em todos os coeficientes avaliados, com valores de 89,00% para o MCC, 88,42% para o Dice e 80,95% para o Jaccard, com desvios padrão relativamente baixos em comparação com outros métodos, ressaltando a habilidade da abordagem proposta em segmentar a região de interesse em imagens de AVC, através do emprego de parâmetros que

mensuram o quanto a região segmentada pelo método corresponde realmente às bordas da região almejada para a segmentação.

Em comparação com outros métodos, podemos observar que alguns apresentaram resultados bastante discrepantes, com desvios padrão bastante elevados, como é o caso do método proposto por (BRAGA *et al.*, 2017), que apresentou valores médios de 67,04% para o MCC, 61,90% para o Dice e 49,60% para o Jaccard, com desvios padrão de 20,15%, 24,53% e 27,23%, respectivamente. Por outro lado, o método proposto por (REBOUÇAS *et al.*, 2017) apresentou resultados próximos aos do FPLS, com valores médios de 89,27% para o MCC, 88,85% para o Dice e 80,50% para o Jaccard, com desvios padrão um pouco maiores.

Esses resultados evidenciam que a segmentação de lesões cerebrais em imagens de AVC é uma tarefa desafiadora e que há uma grande variação nos resultados obtidos pelos diferentes métodos propostos na literatura. Além disso, os desvios padrão apresentados na tabela indicam que há uma variabilidade considerável nos resultados obtidos em diferentes amostras de imagens, o que sugere que é importante avaliar a efetividade dos métodos em diferentes conjuntos de imagens.

Tabela 3 – Resultados do Coeficiente de Correlação de Matthews (MCC), Coeficiente de Similaridade (Dice) e Índice de Jaccard (Jac) com seus respectivos desvios padrão. Os valores destacados em negrito correspondem ao método proposto e os melhores resultados estão destacados em verde.

Métodos	MCC(%)	Dice(%)	Jac(%)
FPLS	89,00 ± 03,86	88,42 ± 06,68	80,95 ± 09,71
(BRAGA <i>et al.</i> , 2021)	87,33 ± 05,35	86,74 ± 06,29	77,07 ± 08,63
(BRAGA <i>et al.</i> , 2017)	67,04 ± 20,15	61,90 ± 24,53	49,60 ± 27,23
(REBOUÇAS <i>et al.</i> , 2017)	89,27 ± 05,78	88,85 ± 06,51	80,50 ± 09,79
(ROUHI <i>et al.</i> , 2015)	80,58 ± 16,90	79,26 ± 18,30	68,23 ± 17,20
(KÖRBES; LOTUFO, 2010)	86,87 ± 07,41	86,63 ± 07,84	77,17 ± 11,20

Tabela 4 – Tempo de convergência dos métodos avaliados. Os valores destacados em negrito correspondem ao método proposto e os melhores resultados estão destacados em verde.

Métodos	Tempo (s)
FPLS	1,50 ± 0,02
(BRAGA <i>et al.</i> , 2021)	0,12 ± 0,01
(BRAGA <i>et al.</i> , 2017)	1,76 ± 0,38
(REBOUÇAS <i>et al.</i> , 2017)	1,76 ± 0,29
(ROUHI <i>et al.</i> , 2015)	3,10 ± 1,70
(KÖRBES; LOTUFO, 2010)	4,80 ± 0,62

Avaliando a Tabela 4, é possível observar que o FPLS obteve um tempo de segmenta-

ção de 1,50s, representando o segundo menor tempo quantos aos valores alcançados pelos outros métodos citados. Logo, a abordagem proposta o FPLS mostra-se mais rápida que a média geral dos tempos, que equivale a 2,17s. Desse modo, o FPLS confirma sua eficiência computacional, dispondo ainda de um dos menores valores de desvio padrão, sendo de apenas $\pm 0,02$.

4.2 Pulmão

Esta subseção apresenta os resultados e comparações obtidos a partir do conjunto de dados do pulmão. As análises foram divididas em abordagens supervisionadas e não supervisionadas, com o objetivo de avaliar diferentes técnicas de segmentação encontradas na literatura para esse conjunto de dados. Para isso, foram utilizadas métricas quantitativas e de similaridade, com três métricas para cada grupo.

As métricas quantitativas incluem Sensibilidade (Sen), Acurácia (Acc) e Coeficiente de Correlação de Matthews (MCC), que permitem avaliar o desempenho do método em relação à segmentação de áreas de interesse nos pulmões. Por sua vez, as métricas de similaridade são a Distância de Hausdorff (HD), Coeficiente de Similaridade de Dados (Dice) e Índice de Jaccard (Jac), que medem a similaridade entre a segmentação obtida e a segmentação de referência.

Considerando as abordagens do tipo não supervisionadas e analisando as Tabelas 5 e 6, podemos inferir que o método proposto obteve os melhores resultados em todas as métricas, obtendo 98,57%, 98,97%, 94,73%, 4,24, 95,51% e 91,45%, em Sensibilidade, Acurácia e Coeficiente de Correlação de Matthews, Distância de Hausdorff, Coeficiente de Similaridade de Dados e Índice de Jaccard, respectivamente. Isso sugere que o método proposto pode ser mais adequado para segmentação de imagens de pulmão, pois é capaz de produzir segmentações mais precisas e acuradas.

Tabela 5 – Índices quantitativos usando métodos de segmentação não supervisionados. Os valores destacados em negrito correspondem ao método proposto e os melhores resultados estão destacados em verde.

Métodos	Índices Quantitativos			
	Referências	Sen	Acc	MCC
FPLS	Método Proposto	98,57±01,78	98,97±00,65	94,73±01,50
VFC	(XU; PRINCE, 1998)	98,26±01,31	97,88±01,29	92,13±03,20
GVF	(LI; ACTON, 2006)	96,75±05,10	96,79±03,61	90,00±06,45
THR mod	(ALEXANDRIA <i>et al.</i> , 2010)	98,22±01,28	97,56±01,63	91,34±03,09
THR multi	(ALEXANDRIA <i>et al.</i> , 2010)	97,68±03,45	95,77±3,96	85,38±11,85

Realizando a comparação com as abordagens supervisionadas, como apresentado

Tabela 6 – Índices de similaridade com FPLS em relação a métodos de segmentação não supervisionados. Os valores destacados em negrito correspondem ao método proposto e os melhores resultados estão destacados em verde.

Métodos	Índices de Similaridade			
	Referências	HD	Dice	Jac
FPLS	Método proposto	4,24 ± 0,43	95,51 ± 1,42	91,45 ± 2,62
VFC	(XU; PRINCE, 1998)	6,92 ± 1,50	93,33 ± 2,82	87,62 ± 4,81
GVF	(LI; ACTON, 2006)	7,55 ± 2,29	91,76 ± 4,84	85,11 ± 7,71
THR mod	(ALEXANDRIA <i>et al.</i> , 2010)	6,93 ± 1,79	92,81 ± 2,21	86,65 ± 3,79
THR multi	(ALEXANDRIA <i>et al.</i> , 2010)	8,23 ± 2,91	87,29 ± 11,18	78,82 ± 14,43

na Tabela 7, o FPLS obteve valores satisfatórios para Sensibilidade, Acurácia e Coeficiente de Correlação de Matthews, todos acima de 90,00%, com 98,57%, 98,77% e 94,73%, respectivamente. Além disso, é importante destacar que a inferioridade da abordagem proposta em relação aos melhores resultados obtidos pelos métodos supervisionados é inferior a 1%. Outro ponto relevante é que o FPLS apresentou os menores valores de desvio-padrão tanto na Acurácia ($\pm 0,65$) quanto no Coeficiente de Correlação de Matthews ($\pm 1,50$). Isso indica que o método proposto é consistente e confiável em sua performance de segmentação de imagens de pulmão.

Tabela 7 – Índices quantitativos usando métodos de segmentação supervisionados. Os valores destacados em negrito correspondem ao método proposto e os melhores resultados estão destacados em verde.

Métodos	Índices Quantitativos			
	Referências	Sen	Acc	MCC
FPLS	Método proposto	98,57±01,78	98,77±00,65	94,73±01,50
NBLS	(BRAGA <i>et al.</i> , 2021)	82,48 ± 6,16	97,17 ± 1,09	88,54 ± 3,67
MLS	(BRAGA <i>et al.</i> , 2017)	97,39 ± 2,87	98,84 ± 0,46	95,55 ± 1,38
FGAC	(MEDEIROS <i>et al.</i> , 2019a)	99,21±00,66	98,86±00,46	95,54±01,32
OPS-Euclidean	(FILHO <i>et al.</i> , 2019b)	99,00±0,79	98,93±0,53	96,14±1,29
SISDEP	(FELIX <i>et al.</i> , 2009)	98,99±0,65	98,89±0,52	95,87±1,13
CRISP	(Rebouças Filho <i>et al.</i> , 2011)	98,01±1,23	98,04±0,89	92,67±2,73
CRAD	(Rebouças Filho <i>et al.</i> , 2014)	99,45±0,43	98,99±0,57	96,13±1,86

A Tabela 8 apresenta uma comparação dos índices de similaridade entre o método proposto, FPLS, e outros métodos de segmentação supervisionados em imagens de pulmão. O FPLS obteve resultados superiores na Distância de Hausdorff, com um valor de $4,24 \pm 0,43$, o que indica uma alta precisão na segmentação das bordas do pulmão. Em outras palavras, quanto menor o valor da Distância de Hausdorff calculada mais eficiente é o algoritmo em detectar a estrutura procurada em uma imagem.

Além disso, o FPLS apresentou valores efetivos para o Coeficiente de Similaridade de Dados e o Índice de Jaccard, com valores superiores a 90% para ambos os índices, sendo 95,51% e 91,45% para o Dice e Jac, respectivamente. O fato de o Dice ser mais prevalente do

que o Índice de Jaccard é positivo, pois o Dice é menos sensível a conjuntos de dados mais heterogêneos e a valores discrepantes.

Os outros métodos de segmentação supervisionados apresentados na tabela também obtiveram resultados expressivos, mas o FPLS se destacou como o método mais eficaz em segmentar as bordas do pulmão nas imagens, de acordo com os índices de similaridade avaliados.

Tabela 8 – Índices de similaridade com FPLS em relação aos métodos de segmentação supervisionados. Os valores destacados em negrito correspondem ao método proposto e os melhores resultados estão destacados em verde.

Métodos	Índices de Similaridade			
	Referências	HD	Dice	Jac
FPLS	Método proposto	4,24±0,43	95,51±1,42	91,45±2,62
NBLS	(BRAGA <i>et al.</i> , 2021)	119,44 ± 39,58	89,71 ± 4,01	81,57 ± 6,18
MLS	(BRAGA <i>et al.</i> , 2017)	88,89 ± 31,43	96,23 ± 1,34	92,76 ± 2,45
FGAC	(MEDEIROS <i>et al.</i> , 2019a)	5,57 ± 1,17	96,19 ± 1,93	92,73 ± 3,43
OPS-Euclidean	(FILHO <i>et al.</i> , 2019b)	5,29 ± 1,14	96,76 ± 1,12	93,75 ± 2,09
SISDEP	(FELIX <i>et al.</i> , 2009)	5,46 ± 1,15	96,52 ± 1,01	93,30 ± 1,87
CRISP	(Rebouças Filho <i>et al.</i> , 2011)	6,33 ± 1,32	93,73 ± 2,70	88,31 ± 4,56
CRAD	(Rebouças Filho <i>et al.</i> , 2014)	5,14 ± 1,17	96,73 ± 1,73	93,72 ± 3,15

A Tabela 9 apresenta uma análise comparativa do tempo médio de segmentação do método FPLS em relação a outros métodos. É possível observar que o método proposto alcançou um tempo de segmentação de 1,32s, que se destaca como um dos menores tempos obtidos, ficando atrás apenas do método NBLS, que obteve o menor tempo de 0,13s.

Embora o FPLS não tenha o menor tempo de segmentação, é importante destacar que ele ainda é muito mais rápido do que a média geral dos tempos dos métodos pontuados, que corresponde a 288,07s. Além disso, o FPLS apresenta um desvio padrão de apenas ± 0,09, o que indica que ele é uma abordagem estável e confiável.

Tabela 9 – Tempo médio de segmentação do FPLS em relação a outros métodos. Os valores destacados em negrito correspondem ao método proposto e os melhores resultados estão destacados em verde.

Métodos	Tempo médio (s)
FPLS	001.32 ± 0.09
NBLS	000,13 ± 0,02
MLS	002,01 ± 0,46
GVF	240,00 ± 3,05
VFC	030,00 ± 2,67
OPS Euclidean	005,86 ± 1,96
SISDEP	004,90 ± 2,02
CRAD	002,00 ± 0,16
FGAC	001,85 ± 0,50

Dessa forma, pode-se afirmar que o FPLS é uma abordagem computacionalmente eficiente para a segmentação de pulmões, já que consegue obter tempos de processamento comparáveis ou até mesmo melhores do que outros métodos, além de apresentar uma boa estabilidade em seus resultados.

4.3 Pele

Nesta subseção, apresentamos os resultados e comparações obtidos utilizando o conjunto de dados de imagens de lesões de pele. Todos os métodos avaliados utilizaram o mesmo conjunto de imagens, garantindo uma comparação justa e precisa. Para avaliar de forma abrangente a qualidade da segmentação de imagens de lesões de pele realizada pelos diferentes métodos, utilizamos cinco métricas diferentes: Índice de Jaccard (Jac), Coeficiente de Similaridade de Dados (Dice), Sensibilidade (Sen), Especificidade (Esp) e Acurácia (Acc). É importante mencionar que alguns trabalhos utilizaram um grupo de métricas, enquanto outros utilizaram outro grupo, e, portanto, tentamos utilizar o máximo de métricas em comum dos métodos que estamos comparando.

De acordo com a Tabela 10, os resultados obtidos pelo FPLS são bastante promissores para o problema de classificação de lesões de pele. O método alcançou valores elevados em todas as métricas avaliadas, incluindo Índice de Jaccard, Coeficiente de Similaridade de Dados, Sensibilidade, Especificidade e Acurácia. Especificamente, o FPLS obteve um Índice de Jaccard de 85,09%, uma Sensibilidade de 93,02%, uma Especificidade de 93,21%, e uma Acurácia de 94,25%.

Tabela 10 – Comparação do FPLS com os estudos mais recentes sobre segmentação de lesões de pele considerando Índice de Jaccard (Jac), Coeficiente de Dice (Dice), Sensibilidade (Sen), Especificidade (Esp) e Acurácia (Acc) como métricas de avaliação. Os valores destacados em negrito correspondem ao método proposto e os melhores resultados estão destacados em verde.

Métodos	Referências	Jac	Dice	Sen	Esp	Acc
Flog Parzen Level Set	Método proposto	85.09	92.49	93.02	93.21	94.25
Median Narrow Band Level Set	(BRAGA <i>et al.</i> , 2021)	81.00	89.16	85.53	97.30	93.62
Median Level Set	(BRAGA <i>et al.</i> , 2017)	76.87	86.49	79.09	98.36	92.30
Geodesic Active Contour	(VASCONCELOS <i>et al.</i> , 2019)	86.16	92.17	91.72	97.99	94.59
Delaunay Triangulation	(PENNISI <i>et al.</i> , 2016)	-	-	80.24	97.22	89.66
Clustering-Based	(PATINO <i>et al.</i> , 2018)	-	-	91.04	89.73	90.39
Deep Convolutional Network Pixel Wise Segmentation	(BADRINARAYANAN <i>et al.</i> , 2015)	80,77	89,36	86,53	96,61	93,36
Full Resolution Convolution Networks	(AL-MASNI <i>et al.</i> , 2018)	84,79	91,77	93,72	95,65	95,08
FCN Encoder-Decoder	(BAGHERSALIMI <i>et al.</i> , 2019)	85,30	91,50	-	-	-
Deep Class-Specific Learning Features Segmentation	(BI <i>et al.</i> , 2019)	85,90	92,10	96,23	94,52	95,30

Embora outros métodos avaliados na Tabela 10 tenham utilizado *Deep Learning*, o FPLS conseguiu competir de forma comparável, com uma variação de valores que não ultrapassou 6% em nenhuma das métricas avaliadas. Além disso, a abordagem do FPLS é diferente da maioria dos métodos de *Deep Learning*, o que destaca ainda mais sua eficácia.

O método proposto atingiu o valor do Coeficiente de Similaridade de Dados (Dice) de 92,49%, o melhor entre as outras abordagens comparadas, sendo que valores maiores que 70,00% indicam uma correspondência adequada entre a verdade fundamental e as regiões segmentadas, ou seja, o método proposto mostrou-se eficaz para a segmentação de lesões de pele.

Observa-se ainda que os índices de similaridade Dice e Jaccard apresentaram discrepância em seus valores, no entanto, a superioridade do coeficiente Dice em relação ao Jaccard foi avaliada de forma positiva. Isso se deve ao fato de que o coeficiente Dice atribui menor relevância a *outliers* e confere um peso duplicado às coocorrências positivas.

Além disso, é interessante notar que o FPLS apresentou uma constância nos valores de Sensibilidade e Especificidade, que são métricas fundamentais para a avaliação de classificadores. Apesar de não ter alcançado o maior valor em ambas as métricas, o FPLS apresentou valores superiores a 90%, com uma variação menor do que 1% entre elas, o que confere maior confiabilidade aos resultados obtidos.

Quanto ao tempo de processamento, o FPLS atingiu um tempo de segmentação por imagem de 2,1s, conforme mostrado na Tabela 11, o qual representa o segundo menor tempo retornado. O método proposto mostra-se ainda bem mais rápido do que a média geral dos tempos, que corresponde ao valor de 6,45s. Desse modo, o FPLS demonstra estabilidade e eficiência computacional.

Tabela 11 – Tempo médio de segmentação por imagem. Os valores destacados em negrito correspondem ao método proposto e os melhores resultados estão destacados em verde.

Métodos	Tempo por Imagem (s)
FPLS	2,1
NBLS	1,3
MLS	3,7
FGAC	2,3
FrCN	9,7
FCN	10,6
U-Net	10,9
SegNet	11,1

4.4 Conclusão do Capítulo

Neste capítulo, foram apresentados e discutidos os resultados experimentais da segmentação em regiões de AVC em imagens de TC do crânio, dos pulmões em imagens de TC do tórax e de lesões de pele em imagens digitais, obtidos pelas abordagens de segmentação propostas nesta tese. Os resultados alcançados demonstram a eficiência do método FPLS em sistemas que auxiliam no diagnóstico médico, tornando-o uma opção promissora para aplicações práticas.

É importante destacar que o método proposto apresenta uma velocidade de segmentação e processamento de informações para diagnóstico médico superior em comparação à maioria dos outros métodos, mantendo a eficácia e confiabilidade dos resultados, mesmo com baixo custo computacional. Isso indica que a abordagem proposta é uma alternativa viável e econômica para segmentação de imagens médicas, especialmente em aplicações que exigem rapidez e eficiência.

No próximo capítulo, serão apresentadas conclusões sobre os resultados e a abordagem proposta, avaliando em detalhes os objetivos específicos e gerais estabelecidos no início desta tese.

5 CONCLUSÕES E TRABALHOS FUTUROS

Neste capítulo são apresentadas as conclusões desta tese, obtidas a partir da consideração dos objetivos, dos aspectos metodológicos, e da análise e discussão dos resultados de segmentação obtidos nos experimentos em imagens de TC do crânio e do tórax, bem como de imagens digitais de lesões de pele. Por fim, são apresentadas as perspectivas de trabalhos.

5.1 Conclusões

Esta tese apresentou uma abordagem de *level set* usando uma estimação não paramétrica com base na janela de parzen para segmentação automática de regiões de interesse em imagens médicas, visando o auxílio ao diagnóstico e realizando experimentos na segmentação de AVC em imagens de TC do crânio, dos pulmões em imagens de TC e de lesões de pele em imagens digitais.

Além de avaliar os resultados obtidos pelo método proposto, esta tese também teve como objetivo apresentar e comparar diferentes métodos convencionais e recentes na literatura, de origens e funcionamentos diversos, aplicados na segmentação das regiões de interesse em cada experimento realizado. Ademais, a tese também incluiu a comparação com métodos de *level set* recentes nas mesmas aplicações. Com base nos resultados apresentados em cada experimento, pode-se concluir que esse objetivo foi atingido de forma satisfatória. As tabelas de resultados, análises e discussões foram produzidas considerando essa revisão bibliográfica, permitindo uma comparação abrangente dos métodos avaliados.

Quanto à proposta de inicialização do *level set* zero dentro da região de interesse, pode-se concluir que o método proposto foi satisfatório em todas as imagens analisadas quanto a auxiliar o *level set* proposto a cumprir seu objetivo com eficácia.

Vale ressaltar, que em todas as aplicações avaliadas, visando o auxílio ao diagnóstico médico, foram consideradas não apenas imagens saudáveis, mas também imagens com regiões que apresentam doenças e anomalias, fatores estes, que dificultam determinar onde se encontram as regiões de interesse de forma eficaz, o que era contornado com a evolução da região com o método FPLS proposto.

Quanto à proposta de usar estimação baseada na janela de Parzen em substituição às funções de densidade probabilidade convencionais para evolução dos métodos de *level set*, desde sua inicialização no *level set* zero até a estabilidade da curva, pode-se concluir que o método

proposto cumpriu este objetivo com sucesso apresentando-se como um método promissor na segmentação das regiões de interesse, notadamente no auxílio ao diagnóstico médico como nos experimentos realizados.

Considerando o método proposto na segmentação de regiões de AVC em imagens de TC do crânio, o método proposto obteve os maiores índices em todas as métricas de desempenho consideradas, tanto em métricas baseadas em erros de falso positivo e falso negativo, quanto em métodos baseados em similaridade como Coeficiente de Correlação de Matthews, no Coeficiente de Similaridade de Dados e Índice de Jaccard. É importante ressaltar que, embora o método proposto não tenha sido o mais rápido entre os métodos avaliados, ele ainda é mais rápido que a média dos demais métodos.

Ademais, é importante destacar que a precisão da segmentação obtida pelo método proposto superou a do método mais rápido avaliado, o que reforça ainda mais sua superioridade. Isso significa que o método proposto apresentou um desempenho promissor em relação às métricas de desempenho consideradas, além de fornecer uma segmentação mais precisa das regiões de AVC em imagens de TC do crânio. Diante desses resultados, podemos concluir que o método proposto é altamente recomendado para uso clínico, uma vez que é capaz de entregar resultados precisos em um tempo razoável, permitindo uma tomada de decisão mais eficiente e segura.

Quanto aos resultados obtidos na segmentação dos pulmões em imagens de TC do tórax, pode-se inferir que o método proposto obteve os melhores resultados em todas as métricas, tanto quantitativas quanto de similaridade considerando as abordagens do tipo não supervisionadas. Considerando os métodos supervisionados, o método proposto não obteve as menores métricas, entretanto a diferença para os melhores resultados é inferior a 1%, e ainda é mais estável já que obteve o menor desvio padrão na acurácia e no Coeficiente de Correlação de Matthews. Quanto ao tempo para realizar a segmentação, o método proposto alcançou um tempo de segmentação de 1,32s, que simboliza o terceiro menor valor obtido em comparação aos tempos dos outros métodos pontuados, mas ainda bem menor que a média geral dos métodos considerados.

Quanto aos resultados obtidos na segmentação de lesões de pele, o método proposto atingiu o maior valor do Coeficiente de Similaridade de Dados com valor de 92,49%, demonstrando eficácia na segmentação de lesões de pele. Nas demais métricas, os resultados obtidos são semelhantes aos demais resultados, com valores ligeiramente superiores, enquanto mantém

um tempo computacional baixo em relação à média geral. No entanto, vale ressaltar que este método não é o mais em comparação com os demais métodos avaliados.

Portanto, considerando a análise geral dos resultados obtidos, pode-se concluir que o método FPLS proposto é recomendável na segmentação de regiões de interesse, sendo promissor na análise de imagens de pacientes sadios, bem como em imagens que apresentem regiões com doença e anomalias. Sendo assim, o método pode ser integrado em sistemas de auxílio ao diagnóstico médico, seja na etapa do diagnóstico ou acompanhamento da doença ao longo do tratamento, notadamente na análise de AVC em imagens de TC do crânio, dos pulmões, em imagens de TC do tórax e de lesões de pele em imagens digitais.

5.2 Trabalhos Futuros

Dentre as sugestões para trabalhos futuros, destacam-se:

- desenvolver um sistema web que identifique e segmente regiões afetadas por AVC em imagens de TC do crânio, bem como sistemas web para identificar e segmentar lesões de pele em imagens digitais e também os pulmões em imagens de TC do tórax;
- estudar, aplicar e avaliar outras funções de estimação que tenham como base o aprendizado de máquina em substituição das funções de densidade probabilidade em abordagens de *level set* para segmentação de regiões de interesse;
- aplicar e adequar o método *level set* proposto a outras aplicações médicas;
- estender o uso da abordagem proposta para outras aplicações que não sejam destinadas ao auxílio ao diagnóstico médico.

REFERÊNCIAS

- AKKOOI, A. van; BERKING, C.; GRIEWANK, K.; GUTZMER, R.; HAUSCHILD, A.; STANG, A.; ROESCH, A.; UGUREL, S. Melanoma. **The Lancet**, v. 392, p. 971–984, 09 2018.
- AL-MASNI, M. A.; AL-ANTARI, M. A.; CHOI, M.-T.; HAN, S.-M.; KIM, T.-S. Skin lesion segmentation in dermoscopy images via deep full resolution convolutional networks. **Computer Methods and Programs in Biomedicine**, v. 162, p. 221 – 231, 2018. ISSN 0169-2607.
- ALEXANDRIA, A.; CORTEZ, P.; FÉLIX, J.; CAVALCANTE, T.; FILHO, P. P. R.; JÚNIOR, J. A. S. Hilbertian energy: a method for external energy calculation on radial active contours. In: **17th International Conference on Systems, Signals and Image Processing–IWSSIP 2010**. [S.l.: s.n.], 2010.
- ALVES, S. S. A.; REBOUÇAS, E. de S.; OLIVEIRA, S. A. F. de; BRAGA, A. M.; FILHO, P. P. R. Lung diseases classification by analysis of lung tissue densities. **IEEE Latin America Transactions**, IEEE, v. 18, n. 09, p. 1329–1336, 2020.
- AMERICAN HEART ASSOCIATION AND AMERICAN STROKE ASSOCIATION. **What are the types of stroke?** 2016. <http://www.strokeassociation.org/STROKEORG/AboutStroke/About-Stroke_UCM_308529_SubHomePage.jsp>. Acessado em: 26 de janeiro de 2016.
- ARABNIA, H. R.; TRAN, Q. N. Emerging trends in applications and infrastructures for computational biology, bioinformatics, and systems biology. **Systems and Applications**, Morgan Kaufmann, 2016.
- ARCHAMBEAU, C.; VALLE, M.; ASSENZA, A.; VERLEYSSEN, M. Assessment of probability density estimation methods: Parzen window and finite gaussian mixtures. In: **IEEE. 2006 IEEE International Symposium on Circuits and Systems**. [S.l.], 2006. p. 4–pp.
- BADRINARAYANAN, V.; KENDALL, A.; CIPOLLA, R. Segnet: A deep convolutional encoder-decoder architecture for image segmentation. **arXiv preprint arXiv:1511.00561**, 2015.
- BAGHERSALIMI, S.; BOZORGTABAR, B.; SCHMID-SAUGEON, P.; EKENEL, H.; THIRAN, J.-P. Dermonet: densely linked convolutional neural network for efficient skin lesion segmentation. **EURASIP Journal on Image and Video Processing**, v. 2019, 07 2019.
- BEAUCHEMIN, M.; THOMSON, K.; EDWARDS, G. On the hausdorff distance used for the evaluation of segmentation results. **Canadian Journal of Remote Sensing**, Taylor Francis, v. 24, n. 1, p. 3–8, 1998.
- BERTELS, J.; EELBODE, T.; BERMAN, M.; VANDERMEULEN, D.; MAES, F.; BISSCHOPS, R.; BLASCHKO, M. **Optimizing the Dice Score and Jaccard Index for Medical Image Segmentation: Theory Practice**. 2019.
- BI, L.; KIM, J.; AHN, E.; KUMAR, A.; FENG, D.; FULHAM, M. Step-wise integration of deep class-specific learning for dermoscopic image segmentation. **Pattern Recognition**, v. 85, p. 78 – 89, 2019. ISSN 0031-3203.
- BISHOP, C. M. **Pattern Recognition and Machine Learning (Information Science and Statistics)**. Secaucus, NJ, USA: Springer-Verlag New York, Inc., 2006. ISBN 0387310738.

BOWERMAN, K. L.; REHMAN, S. F.; VAUGHAN, A.; LACHNER, N.; BUDDEN, K. F.; KIM, R. Y.; WOOD, D. L.; GELLATLY, S. L.; SHUKLA, S. D.; WOOD, L. G. *et al.* Disease-associated gut microbiome and metabolome changes in patients with chronic obstructive pulmonary disease. **Nature communications**, Nature Publishing Group, v. 11, n. 1, p. 1–15, 2020.

BOYLE, P.; DORÉ, J.-F.; AUTIER, P.; RINGBORG, U. Cancer of the skin: a forgotten problem in europe. **Annals of Oncology**, Elsevier BV, v. 15, n. 1, p. 5–6, jan. 2004.

BRAGA, A. M. **Um algoritmo rápido de level set para segmentação hierárquica de núcleos de células cervicais e sua massa citoplasmática**. Dissertação (Mestrado) — Instituto Federal de Educação, Ciência e Tecnologia do Ceará, Pós-graduação em Engenharia de Telecomunicações, julho 2016. Dissertação de Mestrado.

BRAGA, A. M.; MARQUES, R. C.; MEDEIROS, F. N.; NETO, J. F. R.; BIANCHI, A. G.; CARNEIRO, C. M.; USHIZIMA, D. M. Hierarchical median narrow band for level set segmentation of cervical cell nuclei. **Measurement**, v. 176, p. 109232, 2021. ISSN 0263-2241.

BRAGA, A. M.; MARQUES, R. C. P.; RODRIGUES, F. A. A.; MEDEIROS, F. N. S. de. A median regularized level set for hierarchical segmentation of SAR images. **IEEE Geosci. Remote. Sens. Lett.**, v. 14, n. 7, p. 1171–1175, 2017.

CANCELA, D. M. G. O acidente vascular cerebral - classificação, principais consequências e reabilitação. **Porto: ULP**, 2008.

CASELLES, V.; SAPIRO, G.; CHUNG, D. Vector median filters, vector morphology, and coupled pde's: Theoretical connections. **Journal of Mathematical Imaging and Vision**, v. 12, p. 109–120, 2000.

CHAGAS, J. V. S. das; IVO, R. F.; GUIMARÃES, M. T.; RODRIGUES, D. d. A.; REBOUÇAS, E. d. S.; FILHO, P. P. R. Fast fully automatic skin lesions segmentation probabilistic with parzen window. **Computerized Medical Imaging and Graphics**, Elsevier, v. 85, p. 101774, 2020.

CHATTERJEE, R.; MAITRA, T.; Hafizul Islam, S.; HASSAN, M. M.; ALAMRI, A.; FORTINO, G. A novel machine learning based feature selection for motor imagery eeg signal classification in internet of medical things environment. **Future Generation Computer Systems**, v. 98, p. 419–434, 2019. ISSN 0167-739X.

CORRIE, P.; HATEGAN, M.; FIFE, K.; PARKINSON, C. Management of melanoma. **British Medical Bulletin**, v. 111, n. 1, p. 149–162, 09 2014. ISSN 0007-1420.

DILDAR, M.; AKRAM, S.; IRFAN, M.; KHAN, H. U.; RAMZAN, M.; MAHMOOD, A. R.; ALSAIARI, S. A.; SAEED, A. H. M.; ALRADDADI, M. O.; MAHNASHI, M. H. Skin cancer detection: a review using deep learning techniques. **International Journal of Environmental Research and Public Health**, Multidisciplinary Digital Publishing Institute, v. 18, n. 10, p. 5479, 2021.

FELIX, J.; CORTEZ, P.; COSTA, R.; FORTALEZA, S.; PEREIRA, E.; HOLANDA, M. Computer-assisted evaluation of pulmonary emphysema in ct scans: comparison between a locally developed system and a freeware system. **Jornal Brasileiro De Pneumologia - J BRAS PNEUMOL**, v. 35, 09 2009.

- FILHO, P. P. R.; BARROS, A. C. da S.; ALMEIDA, J. S.; RODRIGUES, J.; ALBUQUERQUE, V. H. C. de. A new effective and powerful medical image segmentation algorithm based on optimum path snakes. **Applied Soft Computing**, Elsevier, v. 76, p. 649–670, 2019.
- FILHO, P. P. R.; BARROS, C.; RAMALHO, G.; CLAYTON, P.; PAPA, J.; ALBUQUERQUE, V.; TAVARES, J. Automated recognition of lung diseases in ct images based on the optimum-path forest classifier. **Neural Computing and Applications**, v. 31, p. 901–914, 02 2019.
- FILHO, P. P. R.; CORTEZ, P. C.; BARROS, A. C. da S.; ALBUQUERQUE, V. H. C.; TAVARES, J. M. R. S. Novel and powerful 3d adaptive crisp active contour method applied in the segmentation of CT lung images. **Medical Image Analysis**, Elsevier BV, v. 35, p. 503–516, jan. 2017.
- FILHO, P. P. R.; CORTEZ, P. C.; BARROS, A. C. da S.; ALBUQUERQUE, V. H. C.; TAVARES, J. M. R. Novel and powerful 3d adaptive crisp active contour method applied in the segmentation of ct lung images. **Medical Image Analysis**, Elsevier, v. 35, p. 503–516, 2017.
- GARCIA, V.; DOMINGUEZ, H. d. J. O.; MEDEROS, B. Analysis of discrepancy metrics used in medical image segmentation. **IEEE Latin America Transactions**, IEEE, v. 13, n. 1, p. 235–240, 2015.
- GIBOU, F.; FEDKIW, R.; OSHER, S. A review of level-set methods and some recent applications. **Journal of Computational Physics**, Elsevier, v. 353, p. 82–109, 2018.
- GILLEBERT, C. R.; HUMPHREYS, G. W.; MANTINI, D. Automated delineation of stroke lesions using brain CT images. **NeuroImage: Clinical**, Elsevier, v. 4, p. 540–548, 2014.
- GONÇALVES, A.; SANNOMYIA, E. K.; LUGÃO, C. E. B.; GONÇALVES, M. Identificação de pacientes com risco de acidente vascular cerebral pela radiografia panorâmica. **Jornal Brasileiro de Clinica Odontologica Integrada**, v. 8, n. 44, p. 162–164, 2004.
- GUAN, W.-J.; ZHENG, X.-Y.; CHUNG, K. F.; ZHONG, N.-S. Impact of air pollution on the burden of chronic respiratory diseases in china: time for urgent action. **The Lancet**, Elsevier, v. 388, n. 10054, p. 1939–1951, 2016.
- HAN, B.; WU, Y. Active contours driven by global and local weighted signed pressure force for image segmentation. **Pattern Recognition**, Elsevier, v. 88, p. 715–728, 2019.
- HAN, T.; NUNES, V. X.; SOUZA, L. F. D. F.; MARQUES, A. G.; SILVA, I. C. L.; JUNIOR, M. A. A. F.; SUN, J.; FILHO, P. P. R. Internet of medical things—based on deep learning techniques for segmentation of lung and stroke regions in ct scans. **IEEE Access**, IEEE, v. 8, p. 71117–71135, 2020.
- ISLAM, M. M.; LEE, G.; HETTIWATTE, S. N. Application of parzen window estimation for incipient fault diagnosis in power transformers. **High Voltage**, IET, v. 3, n. 4, p. 303–309, 2018.
- KARAGIANNIS, C.; SAVVA, C.; MAMAIS, I.; ADAMIDE, T.; GEORGIU, A.; XANTHOS, T. Treinamento de membros superiores e atividades da vida diária em pacientes com dpoc: revisão sistemática de ensaios controlados randomizados. **Jornal Brasileiro de Pneumologia**, SciELO Brasil, v. 46, 2020.
- KATAN, M.; LUFT, A. Global burden of stroke. In: GEORG THIEME VERLAG. **Seminars in Neurology**. [S.l.], 2018. v. 38, n. 2, p. 208–211.

- KATOPODES, N. D. **Free-Surface Flow: Computational Methods**. [S.l.]: Butterworth-Heinemann, 2018.
- KÖRBES, A.; LOTUFO, R. **Analysis of Algorithms of the Watershed Transform**. Dissertação (Mestrado) — Universidade Estadual de Campinas. Faculdade de Engenharia Elétrica e de Computação, 2010.
- LELIEVELD, J.; EVANS, J. S.; FNAIS, M.; GIANNADAKI, D.; POZZER, A. The contribution of outdoor air pollution sources to premature mortality on a global scale. **Nature**, Nature Publishing Group, v. 525, n. 7569, p. 367, 2015.
- LI, B.; ACTON, S. T. Vector field convolution for image segmentation using snakes. In: **IEEE. 2006 IEEE International Conference on Image Processing**. [S.l.], 2006. p. 1637–1640.
- LIU, D.; ZHAO, Y.; KHAMBAMPATI, A. K.; SEPPÄNEN, A.; DU, J. A parametric level set method for imaging multiphase conductivity using electrical impedance tomography. **IEEE Transactions on Computational Imaging**, IEEE, v. 4, n. 4, p. 552–561, 2018.
- MANZI, F. R.; BÓSCOLO, F. N.; ALMEIDA, S. M. de; NETO, F. H. Panoramic radiography as an auxiliary in detecting patients at risk for cerebrovascular accident (CVA): a case report. **Journal of Oral Science**, Nihon University School of Dentistry, v. 45, n. 3, p. 177–180, 2003.
- MARCO, R. D.; ACCORDINI, S.; CERVERI, I.; CORSICO, A.; SUNYER, J.; NEUKIRCH F.; KÜNZLI, N.; LEYNAERT, B.; JANSON, C.; GISLASON, T. *et al.* An international survey of chronic obstructive pulmonary disease in young adults according to gold stages. **Thorax**, BMJ Publishing Group Ltd, v. 59, n. 2, p. 120–125, 2004.
- MARQUES, R. C. P. **Caracterização de Regiões em Imagens de Radar de Abertura Sintética com Aplicações de Segmentação por level set**. Tese (Doutorado) — Universidade Federal do Ceará, Fortaleza, 2011.
- MEDEIROS, A. G.; GUIMARÃES, M. T.; PEIXOTO, S. A.; SANTOS, L. de O.; BARROS, A. C. da S.; REBOUÇAS, E. de S.; ALBUQUERQUE, V. H. C. de; FILHO, P. P. R. A new fast morphological geodesic active contour method for lung CT image segmentation. **Measurement**, Elsevier BV, v. 148, p. 106687, dez. 2019.
- MEDEIROS, A. G.; GUIMARÃES, M. T.; PEIXOTO, S. A.; SANTOS, L. d. O.; BARROS, A. C. da S.; REBOUÇAS, E. d. S.; ALBUQUERQUE, V. H. C. de; FILHO, P. P. R. A new fast morphological geodesic active contour method for lung ct image segmentation. **Measurement**, Elsevier, v. 148, p. 106687, 2019.
- MEDEIROS, A. G.; SANTOS, L. d. O.; SARMENTO, R. M.; REBOUÇAS, E. d. S. *et al.* New adaptive morphological geodesic active contour method for segmentation of hemorrhagic stroke in computed tomography image. In: **SPRINGER. Brazilian Conference on Intelligent Systems**. Rio Grande, Brasil, 2020. p. 604–618.
- MEDEIROS, A. G.; SILVA, F. H.; OHATA, E. F.; PEIXOTO, S. A.; FILHO, P. P. R. An automatic left ventricle segmentation on echocardiogram exams via morphological geodesic active contour with adaptive external energy. **Journal of Artificial Intelligence and Systems**, v. 1, p. 77–95, 2019.
- MENDONCA, T.; CELEBI, M.; MENDONCA, T.; MARQUES, J. Ph2: A public database for the analysis of dermoscopic images. **Dermoscopy Image Analysis**, CRC Press, 2015.

MENDONCA, T.; FERREIRA, P. M.; MARQUES, J. S.; MARCAL, A. R. S.; ROZEIRA, J. PHsup2/sup - a dermoscopic image database for research and benchmarking. In: **2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)**. Osaka, Japan: IEEE, 2013.

MESSAY, T.; HARDIE, R. C.; ROGERS, S. K. A new computationally efficient CAD system for pulmonary nodule detection in CT imagery. **Medical Image Analysis**, v. 14, n. 3, p. 390–406, 2010. ISSN 1361-8415.

METZ, C. E. Basic principles of roc analysis. **Seminars in Nuclear Medicine**, v. 8, n. 4, p. 283–298, 1978. ISSN 0001-2998.

MITICHE, A.; AYED, I. B. **Variational and Level Set Methods in Image Segmentation**. Berlin: Springer-Verlag, 2010.

MUKHERJEE, D.; LEVIN, R. L.; HELLER, W. The cognitive, emotional, and social sequelae of stroke: psychological and ethical concerns in post-stroke adaptation. **Topics in Stroke Rehabilitation**, Taylor & Francis, v. 13, n. 4, p. 26–35, 2006.

MÜLLER, D.; SOTO-REY, I.; KRAMER, F. Towards a guideline for evaluation metrics in medical image segmentation. **BMC Res Notes**, v. 15, n. 1, p. 210, 2022.

OJALA, T.; PIETIKAINEN, M.; HARWOOD, D. Performance evaluation of texture measures with classification based on kullback discrimination of distributions. In: **IEEE. Proceedings of 12th International Conference on Pattern Recognition**. Jerusalem, Israel, 1994. v. 1, p. 582–585.

ORGANIZATION, T. W. H. **Global Tuberculosis Report 2017**. Geneva, Switzerland: World Health Organization, 2017.

ORGANIZATION, W. H. **Global Tuberculosis Report 2013**. Geneva, Switzerland: World Health Organization, 2013.

ORGANIZATION, W. H. **World Health Statistics 2018: Monitoring health for the SDGs**. Geneva, Switzerland: World Health Organization, 2019.

PATINO, D.; ORTEGA, J. A.; BRANCH, J. W. Automatic skin lesion segmentation on dermoscopic images by the means of superpixel merging. **21st International Conference, Granada, Spain**, p. 728–736, 09 2018.

PEIXOTO, S. A.; MEDEIROS, A. G.; HASSAN, M.; DEWAN, M. A.; ALBUQUERQUE, V.; FILHO, P. P. R. Floor of log: a novel intelligent algorithm for 3d lung segmentation in computer tomography images. **Multimedia Systems**, p. 1–13, 2020.

PEIXOTO, S. A.; VASCONCELOS, F. F.; GUIMARÃES AND ALDÍSIO G. MEDEIROS AND PAULO A.L. REGO AND ALOÍSIO V. LIRA NETO AND VICTOR HUGO C. DE ALBUQUERQUE AND PEDRO P. REBOUÇAS FILHO, M. T. A high-efficiency energy and storage approach for iot applications of facial recognition. **Image and Vision Computing**, v. 96, p. 103899, 2020. ISSN 0262-8856.

PENNISI, A.; BLOISI, D. D.; NARDI, D.; GIAMPETRUZZI, A. R.; MONDINO, C.; FACCHIANO, A. Skin lesion image segmentation using delaunay triangulation for melanoma detection. **Computerized Medical Imaging and Graphics**, v. 52, p. 89 – 103, 2016. ISSN 0895-6111.

PHAM, D. L.; XU, C.; PRINCE, J. L. Current methods in medical image segmentation. **Annual Review of Biomedical Engineering**, v. 2, n. 1, p. 315–337, 2000.

PONT-TUSET, J.; MARQUES, F. Measures and meta-measures for the supervised evaluation of image segmentation. In: IEEE; IEEE Comp Soc. **2013 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)**. Portland, Oregon, 2013. p. 2131–2138. ISSN 1063-6919.

PRAKASH, R. M.; SARASWATHY, G.; RAMALAKSHMI, G.; MANGALESWARI, K.; KAVIYA, T. Detection of leaf diseases and classification using digital image processing. In: IEEE. **2017 International Conference on Innovations in Information, Embedded and Communication Systems (ICIIECS)**. Coimbatore, India, 2017. p. 1–4.

QIAN, W.; ZHANG, S.; ZHANG, S.; LI, F.; ZHANG, H.; WU, J.; WANG, X.; WALSH, J. A.; SUN, R. Mapping and candidate-gene screening of the novel turnip mosaic virus resistance gene *retr02* in chinese cabbage (*brassica rapa* l.). **Theoretical and Applied Genetics**, Springer, v. 126, n. 1, p. 179–188, 2013.

REBOUÇAS, E. d. S.; BRAGA, A. M.; SARMENTO, R. M.; MARQUES, R. C.; FILHO, P. P. R. Level set based on brain radiological densities for stroke segmentation in ct images. In: IEEE. **2017 IEEE 30th International Symposium on Computer-Based Medical Systems (CBMS)**. Thessaloniki, Greece, 2017. p. 391–396.

Rebouças Filho, P. P.; CORTEZ, P. C.; BARROS, A. C. S.; ALBUQUERQUE, V. H. C. D. Novel adaptive balloon active contour method based on internal force for image segmentation—A systematic evaluation on synthetic and real images. **Expert Systems with Applications**, Elsevier, v. 41, n. 17, p. 7707–7721, 2014.

Rebouças Filho, P. P.; CORTEZ, P. C.; HOLANDA, M. A. Active contour modes crisp: new technique for segmentation of the lungs in ct images. **Revista Brasileira de Engenharia Biomédica**, v. 27, n. 4, p. 259–72, 2011.

REKIK, I.; ALLASSONNIÈRE, S.; CARPENTER, T. K.; WARDLAW, J. M. Medical image analysis methods in MR/CT-imaged acute-subacute ischemic stroke lesion: Segmentation, prediction and insights into dynamic evolution simulation models. a critical appraisal. **NeuroImage: Clinical**, v. 1, n. 1, p. 164–178, 2012.

ROUHI, R.; JAFARI, M.; KASAEI, S.; KESHAVARZIAN, P. Benign and malignant breast tumors classification based on region growing and cnn segmentation. **Expert Systems with Applications**, Elsevier, v. 42, n. 3, p. 990–1002, 2015.

SARMENTO, R. M.; VASCONCELOS, F. F. X.; FILHO, P. P. R.; WU, W.; ALBUQUERQUE, V. H. C. de. Automatic neuroimage processing and analysis in stroke—a systematic review. **IEEE Reviews in Biomedical Engineering**, IEEE, v. 13, p. 130–155, 2019.

SETHIAN, J. A. **Level Set Methods and Fast Merging Methods: Evolving Interfaces in Computational Geometry, Fluid Mechanics, Comput. Vision and Materials Sci.** Cambridge: Cambridge University Press, 1998.

SHARMA, N.; RAY, A.; SHUKLA, K.; SHARMA, S.; PRADHAN, S.; SRIVASTVA, A.; AGGARWAL, L. Automated medical image segmentation techniques. **Journal of Medical Physics**, Medknow, v. 35, n. 1, p. 3, 2010.

SOUZA, L. F. d. F.; SILVA, I. C. L.; MARQUES, A. G.; SILVA, F. H. d. S.; NUNES, V. X.; HASSAN, M. M.; ALBUQUERQUE, V. H. C. d. *et al.* Internet of medical things: An effective and fully automatic iot approach using deep learning and fine-tuning to lung ct segmentation. **Sensors**, Multidisciplinary Digital Publishing Institute, v. 20, n. 23, p. 6711, 2020.

SUN, M.; HU, R.; YU, H.; ZHAO, B.; REN, H. Intracranial hemorrhage detection by 3D voxel segmentation on brain CT images. In: IEEE. **International Conference on Wireless Communications and Signal Processing (WCSP)**. Nanjing, China, 2015. p. 1–5. ISSN 2325-3746.

TAHA, A. A.; HANBURY, A. Metrics for evaluating 3d medical image segmentation: analysis, selection, and tool. **BMC Medical Imaging**, BioMed Central, v. 15, n. 1, p. 29, 2015.

TSENG, S.-H.; NGUYEN, T. S. Agent-based modeling of rumor propagation using expected integrated mean squared error optimal design. **Applied System Innovation**, Multidisciplinary Digital Publishing Institute, v. 3, n. 4, p. 48, 2020.

VASCONCELOS, F. F.; SARMENTO, R. M.; FILHO, P. P. R.; ALBUQUERQUE, V. H. C. de. Artificial intelligence techniques empowered edge-cloud architecture for brain CT image analysis. **Engineering Applications of Artificial Intelligence**, Elsevier BV, v. 91, p. 103585, maio 2020.

VASCONCELOS, F. F. X.; MEDEIROS, A. G.; PEIXOTO, S. A.; FILHO, P. P. R. Automatic skin lesions segmentation based on a new morphological approach via geodesic active contour. **Cognitive Systems Research**, Elsevier BV, v. 55, p. 44–59, jun. 2019.

VINCENT, P.; BENGIO, Y. Manifold parzen windows. In: UNIVERSITÉ DE MONTRÉAL. **Advances in Neural Information Processing Systems**. Montreal, Canada, 2003. p. 849–856.

XU, C.; PRINCE, J. L. Snakes, shapes, and gradient vector flow. **IEEE Transactions on Image Processing**, IEEE, v. 7, n. 3, p. 359–369, 1998.

XU, Y.; HOLANDA, G.; FABRÍCIO, L.; F, S. de; SILVA, H.; GOMES, A.; SILVA, I.; FERREIRA, M.; JIA, C.; HAN, T.; ; ALBUQUERQUE, V. H. C. de; FILHO, P. P. R. Deep learning-enhanced internet of medical things to analyze brain ct scans of hemorrhagic stroke patients: A new approach. **IEEE Sensors Journal**, IEEE, 2020.

XU, Y.; SOUZA, L. F.; SILVA, I. C.; MARQUES, A. G.; SILVA, F. H.; NUNES, V. X.; HAN, T.; JIA, C.; ALBUQUERQUE, V. H. C. de; FILHO, P. P. R. A soft computing automatic based in deep learning with use of fine-tuning for pulmonary segmentation in computed tomography images. **Applied Soft Computing**, Elsevier, v. 112, p. 107810, 2021.

YEUNG, D.-Y.; CHOW, C. Parzen-window network intrusion detectors. In: IEEE. **2002 International Conference on Pattern Recognition**. Quebec City, Canada, 2002. v. 4, p. 385–388 vol.4.