

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO CEARÁ
PRÓ-REITORIA DE PESQUISA, PÓS-GRADUAÇÃO E INOVAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Aldísio Gonçalves Medeiros

**Um novo método de contorno ativo geodésico rápido para
segmentação de pulmão em imagens de tomografia computadorizada.**

Fortaleza – CE

1 de agosto de 2019

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

MEDEIROS, ALDISIO GONÇALVES MEDEIROS.

Um novo método de contorno ativo geodésico rápido para segmentação de pulmão em imagens de tomografia computadorizada. / ALDISIO GONÇALVES MEDEIROS MEDEIROS. - 2020.
91 f. : il. color.

Dissertação (Mestrado) - Instituto Federal do Ceará, Mestrado em Ciência da Computação, Campus Fortaleza, 2020.

Orientação: Prof. Dr. Prof. Dr. Pedro Pedrosa Rebouças Filho.

1. Método de Contorno Ativo. 2. Contorno Ativo Geodésico Morfológico. 3. Snakes. 4. Segmentação de Imagem Pulmonar. 5. Tomografia Computadorizada. I. Título.

CDD 004

Aldísio Gonçalves Medeiros

**Um novo método de contorno ativo geodésico rápido
para segmentação de pulmão em imagens de tomografia
computadorizada.**

Dissertação submetida ao Programa de Pós-Graduação em Ciência da Computação do Instituto Federal de Educação, Ciência e Tecnologia do Ceará, como requisito parcial para obtenção do grau de Mestre em Ciência da Computação.

Linha de Pesquisa: Processamento Digitais de Sinais e Imagens

Orientador: Prof. Dr. Pedro Pedrosa Rebouças Filho

Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE)

Pró-Reitoria de Pesquisa, Pós-Graduação e Inovação (PRPI)

Programa de Pós-Graduação em Ciência da Computação (PPGCC)

Fortaleza – CE

1 de agosto de 2019



Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE)
Pró-Reitoria de Pesquisa, Pós-Graduação e Inovação (PRPI)
Programa de Pós-Graduação em Ciência da Computação (PPGCC)

Aldísio Gonçalves Medeiros

Esta dissertação foi julgada adequada para a obtenção do título de Mestre em Ciência da Computação, sendo aprovada pela Coordenação do Programa de Pós-Graduação em Ciência da Computação do Instituto Federal de Educação, Ciência e Tecnologia do Ceará e pela banca examinadora:

**Orientador: Prof. Dr. Pedro Pedrosa Rebouças
Filho**

Instituto Federal de Educação, Ciência e Tecnologia do
Ceará (IFCE)

Prof. Dr. Francisco Nivando Bezerra

Instituto Federal de Educação, Ciência e Tecnologia do
Ceará (IFCE), Brasil.

Prof. Dr. Antonio Carlos da Silva Barros

Universidade da Integração Internacional da Lusofonia
Afro-Brasileira (UNILAB), Brasil.

Fortaleza – CE
1 de agosto de 2019

Agradecimentos

A Deus, pela vida e pelas oportunidades que a mim foram ofertadas ao longo do caminho, sem Ele nada do que foi alcançado até aqui seria possível.

Aos meus pais Aldízio Medeiros e Alriline Medeiros, pelos esforços sem medidas dedicados a minha formação acadêmica.

À minha esposa Samara Pinheiro pela paciência, carinho e amor dedicados, você tornou o caminho mais belo e agradável, obrigado por estar sempre ao meu lado.

Aos meus irmãos Adria, Aykon e Renan, pela compreensão nos momentos em que estive ausente, vocês fazem parte desta conquista.

Ao meu orientador Prof. Dr. Pedro Pedrosa Rebouças Filho, por todo o apoio, incentivo, paciência e perseverança, você me concedeu a oportunidade de conhecer um pouco mais o mundo acadêmico, com preciosas instruções a minha formação pessoal e profissional.

À amiga Raphaele Pinheiro pelo apoio, pelas conversas e disposição em contribuir na minha formação acadêmica.

Ao amigo Rafael Matias pelo apoio concedido durante os períodos de aula, estudos e trabalhos.

Finalmente, ao Laboratório de Processamento de Imagens, Sinais e Computação aplicada (LAPISCO) e a todos os seus membros, pelas valiosas discussões e por todo apoio, pelas conversas, pelas críticas construtivas, vocês me ajudaram a ser uma pessoa melhor.

*“Não a nós, Senhor, nenhuma glória para nós, mas sim ao Teu nome, por Teu amor e
por Tua fidelidade!”
Salmo 115:1*

Resumo

Entre as principais causas de morte no mundo ainda se encontram as doenças pulmonares. Nesta perspectiva, imagens médicas têm sido amplamente utilizadas na investigação para a detecção precoce das lesões pulmonares. Assim, a tarefa de identificação automática da região que representa a cavidade pulmonar apresenta relevância no contexto clínico, viabilizando o desenvolvimento de sistemas de auxílio ao diagnóstico. Diante disto, o presente trabalho propõe uma nova abordagem adaptativa para múltipla segmentação de pulmão chamado Contorno Ativo Geodésico Morfológico Rápido (FGAC, do inglês *Fast morphological Geodesic Active Contour*). O método destaca-se por não possuir estágios prévios de treinamento, entretanto, apresenta um desempenho equivalente ou superior a outras abordagens tradicionais e baseadas em treinamento supervisionado. Além disso, o FGAC propõe, em sua construção, um novo detector de borda baseado em lógica *Fuzzy*. A metodologia de avaliação proposta considerou 72 imagens de pulmão a partir de exames de tomografia computadorizada do tórax. As imagens são de voluntários e estão distribuídas igualmente em amostras classificadas como Fibrose, Doença Pulmonar Obstrutiva Crônica (DPOC) e saudáveis. As marcações manuais feitas por um especialista foram consideradas como padrão ouro. Quanto ao resultado das segmentações, o FGAC foi avaliado sob dois pontos de vista: o primeiro diz respeito às medidas quantitativas e o segundo aos índices de similaridade. Ambas análises foram aplicadas a dois grupos com abordagens já consolidadas na literatura, sendo o primeiro grupo representado por métodos tradicionais representado pelos métodos VFC, GVF, THRMod, THRMult. Já o segundo grupo é formado por métodos de segmentação que utilizam conhecimento *a priori* ou estágios de treinamento supervisionados, são eles OPS, SISDEP, Crisp e CRAD. O FGAC apresentou resultados promissores para os índices de similaridade, a saber o coeficiente de Jaccard (92.73%), coeficiente DICE (96.19%) e também o coeficiente de correlação de Matthews (95.54%). Alcançando sensibilidade (99.21%) e acurácia (98.86%) relevantes. Além destes, o tempo médio de segmentação do FGAC alcança 1.98 segundos, indicando um custo de tempo menor que os demais métodos de segmentação considerados, são eles GVF (240s), VFC (30s), OPS com distância euclidiana (5.86s), SISDEP (4.90s) e CRAD (2s). Sugerindo um potencial para aplicações com restrições de tempo. Portanto, diante da metodologia proposta, o FGAC apresenta uma similaridade satisfatória em relação as amostras de referência com um tempo médio de convergência inferior aos demais métodos, indicando sua aderência à sistemas de apoio ao diagnóstico em pulmonologia.

Palavras-chave: Método de Contorno Ativo, Contorno Ativo Geodésico Morfológico, *Snakes*, Segmentação de Imagem Pulmonar, Tomografia Computadorizada.

Abstract

Lung diseases are a main causes of death in the world. Therefore, the task of automatic identification of the region that represents pulmonary cavity is clinical important, enabling the development of diagnostic aid systems. In this sense, this work presents a new adaptive approach for segmentation based on the Geodesic Active Contour method (GAC), called Fast morphological Geodetic Active Contour (FGAC). The method stands out as not has previous training stage, however, its performs is similar or superior to other supervised approaches. Moreover, the FGAC proposes in its construction a new border detector based on *Fuzzy* logic. The proposed evaluation methodology considered 72 lung images from thorax computed tomography. The images are equally distributed in samples with Fibrosis, Chronic Obstructive Pulmonary Disease (COPD) and healthy. A manual segmentation from a specialist was investigated as ground truth. According to segmentation results, the FGAC was evaluated under two perspectives: the first is according to quantitative indexes, and second in relation to similarity indexes. Both analyses were applied to two approaches groups already consolidated in the literature. The first group represented by traditional methods have no training stage, represented by the VFC, GVF, THRMd and THRMdMulti. The second group consists of supervised segmentation methods: OPS, SISDEP, Crisp, and CRAD. The FGAC obtained good results for similarity indices, a Jaccard coefficient (92.73 %), DICE coefficient (96.19 %) and also Matthews correlation coefficient (95.54 %). Reaching relevant sensitivity (99.21 %) and accuracy (98.86 %). Therefore, the average segmentation time of the FGAC reaches 1.98 seconds, with a convergence time lower than the other considered methods, such as GVF (240s), VFC (30s), OPS with Euclidean distance (5.86s), SISDEP (4.90s), and CRAD (2s). Suggesting a great potential for applications with time constraints. The FGAC presents satisfactory similarity to the reference samples with a lowerest convergence time, suggesting its adherence to the computer-aided diagnosis on pneumology.

Keywords: Active Contour Method, Morphological Geodesic Active Contour, Snakes, Lung Image Segmentation, Computed Tomography.

Lista de ilustrações

Figura 1 – Amostras de pulmões com diferentes configurações topológicas e de contraste.	29
Figura 2 – Exemplos de inicialização do MCA Balão. (a) até (d) representa a evolução com inicialização no centro do objeto; (e) até (h) representa uma evolução com inicialização próxima a região côncava, com convergência precoce. Em todos os casos as setas representam a influência da F_{ballon}	35
Figura 3 – Exemplos de inicialização do MCA GVF. (a) até (d) representa a evolução com inicialização no centro do objeto; (e) até (h) representa uma evolução com inicialização descentralizada próxima a borda, com convergência precoce. Em todos os casos as setas representam a influência do campo de fluxo gradiente.	36
Figura 4 – Transformada de Hilbert aplicada a um sinal ruidoso 1D (f). Os picos em $\hat{f}$ indicam as transições do sinal.	37
Figura 5 – Exemplo de atuação da força balão adaptativa F_{OBA} . Fonte: Adaptado de Barros (2016).	42
Figura 6 – Aplicação do contorno ativo geodésico combinado com o operador de curvatura. A linha superior representa a evolução em 3D, já na linha inferior em um plano 2D aplicado em uma componente binária representada pela cor branca. Adaptado de Marquez-Neila, Baumela e Alvarez (2014).	45
Figura 7 – Decomposição HCSD, em (a) árvore de decomposição até o segundo nível; (b) recorte da componente binária sob análise.	47
Figura 8 – Procedimento de inicialização proposto por He et al. (HE et al., 2017).	48
Figura 9 – Procedimento de inicialização proposto por Cid et al. (CID et al., 2015).	49
Figura 10 – Inicialização do OPS, (a) Exame de TC, (b) Energia externa e (c) centroides de inicialização.	49
Figura 11 – Regiões utilizadas para encontrar os pontos para as inicializações da curva nos pulmões esquerdo e direito, nas posições, a) ápice; b) hilo; e c) base. Adaptado de (REBOUÇAS FILHO et al., 2013)	50
Figura 12 – Comparativo entre a aplicação do operador morfológico de Marquez-Neila, Baumela e Alvarez (2014), primeira linha, e o operador de curvatura definido sob a PDF de Evans, Spruck et al. (1991) na contração de uma componente binária branca, indicando a equivalência entre os operadores. Adaptado de Marquez-Neila, Baumela e Alvarez (2014).	56

Figura 13 – Energia externa calculada pelo detector de borda tradicional $g(I)$. (1) A patologia representa a degradação das bordas da região de interesse. (2) A patologia apresenta uma alta degradação da região interna devido a suavização de energia.	57
Figura 14 – Análise estatístico-geométrica do gradiente nas regiões internas a fronteira da cavidade pulmonar, na cor azul, e externas a fronteira na cor laranja. Aqui o gradiente representa o raio entre as regiões circulares definidas pelos índices Kappa e Lambda.	58
Figura 15 – Representação do gradiente gaussiano em variáveis linguísticas. Variáveis: Pulmão, Fronteira e Região Não Desejada (RND).	58
Figura 16 – Energia externa calculada pelo novo detector difuso de fronteira. (1) Observa-se uma melhor separação entre as bordas da região de interesse e as estruturas adjacentes. (2) Não há degradação significativa da região interna do pulmão.	60
Figura 17 – Comparativo entre a energia externa obtida pelo detector tradicional $g(I)$ e o novo detector difuso de fronteira $\Omega(I)$ aplicado em amostras de pulmões saudáveis.	61
Figura 18 – Comparativo entre a energia externa obtida pelo detector tradicional $g(I)$ e o novo detector difuso de fronteira $\Omega(I)$ aplicado em amostras de pulmões com DPOC.	61
Figura 19 – Comparativo entre a energia externa obtida pelo detector tradicional $g(I)$ e o novo detector difuso de fronteira $\Omega(I)$ aplicado em amostras de pulmões com Fibrose.	61
Figura 20 – Representação do corte de contraste no histograma, M corresponde a média global e DC é o parâmetros de deslocamento aplicado.	63
Figura 21 – Histograma das aplicações do Deslocamento de Contraste com diferentes parâmetros DC em um exame de TC do tórax.	64
Figura 22 – Procedimento proposto para identificação do level set de inicialização.	65
Figura 23 – Análise estrutural para separação das componentes pulmonares. A distância média d é calculada para cada amostra, aquelas com distância inferior ao limiar K são identificadas para correção.	66
Figura 24 – Reconstrução morfológica para detecção do Level Set inicial.	67
Figura 25 – Exemplos de inicialização utilizadas pelo FGAC em pulmões saudáveis.	68
Figura 26 – Exemplos de inicialização utilizadas no FGAC em pulmões com DPOC.	68
Figura 27 – Exemplos de inicialização utilizadas pelo FGAC em pulmões com fibrose.	69
Figura 28 – Diagrama do FGAC com a evolução do contorno em uma amostra de TC do tórax, segmentando a região pulmonar.	69
Figura 29 – Diferentes tipos de corte em TC. (a) ápice; (b) hilo; (c) base.	70

Figura 30 – Mapa mental que ilustra a metodologia de avaliação proposta. No canto superior à esquerda, o banco de exames de TC. No centro, as métricas de avaliação. À direita, os métodos de segmentação avaliados frente a abordagem proposta.	71
Figura 31 – Resultado dos índices quantitativos e de similaridade para os parâmetros da gaussiana do FGAC (σ) e força de balão (ν) aplicados ao conjunto de amostras de TC do tórax. Considerando esta análise, os melhores resultados foram obtidos com os parâmetros $\sigma = 4.0$ e $\nu = 0.50$	74
Figura 32 – Comparação entre FGAC e métodos de segmentação não supervisionados. A primeira linha mostra resultados em uma amostra com DPOC, na segunda e terceira pulmão saudáveis e com fibrose, respectivamente.	76
Figura 33 – Segmentação de amostras onde frequentemente outros métodos falham.	77
Figura 34 – Comparação entre FGAC e métodos de segmentação supervisionados. As linhas apresentam amostras com DPOC, saudáveis e com fibrose, respectivamente.	78
Figura 35 – Gráfico de barras com linha de tendência comparativa entre FGAC e os métodos Tradicionais e Supervisionados, sob uma análise quantitativa.	79
Figura 36 – Gráfico de barras com linha de tendência comparativa entre FGAC e os métodos Tradicionais e Supervisionados, sob uma análise de similaridade.	80

Lista de tabelas

Tabela 1	–	Comparação dos tempos médios de segmentação do FGAC em relação aos demais métodos.	72
Tabela 2	–	Melhores configurações das derivadas gaussianas (σ) combinadas com o limiar da Força balão (ν). As diferentes combinações foram avaliadas sob a perspectiva das métricas de similaridade e quantitativas, além do tempo de convergência.	73
Tabela 3	–	Índices quantitativos para o FGAC frente aos métodos de segmentação não supervisionados.	75
Tabela 4	–	Índices quantitativos para FGAC contra métodos de segmentação supervisionados.	75
Tabela 5	–	Índices de similaridade para FGAC em comparação com os métodos de segmentação não supervisionados.	76
Tabela 6	–	Índices de similaridade para o FGAC em relação aos métodos de segmentação supervisionados.	77

Lista de abreviaturas e siglas

CAD	Diagnóstico Auxiliado por Computador (<i>Computer-Aided Diagnosis</i>)
CRAD	Crisp Adaptativo
DPOC	Doença Pulmonar Obstrutiva Crônica
FGAC	Contorno Ativo Geodésico Morfológico Rápido (<i>Fast morphological Geodesic Active Contour</i>)
GVF	Fluxo de Vetor Gradiente (<i>Gradient Vector Flow</i>)
MCA	Método de Contorno Ativo
MCAG	Método de Contorno Ativo Geodésico
OPS	<i>Optimum Path Snake</i>
PPV	Valor Preditivo Positivo
Sen	Sensibilidade
SISDEP	Sistema para a Detecção e a quantificação de Enfisema Pulmonar
Spe	Especificidade
TC	Tomografia Computadorizada
THR-Mod	Transformada de Hilbert Radial Multidirecional Modular
THR-Multi	Transformada de Hilbert Radial Multidirecional
VFC	Convolução de Campo de Vetor (<i>Vector Field Convolution</i>)

Lista de símbolos

ω	Letra grega Ômega minúsculo, indica o mínimo local.
Ω	Letra grega Ômega maiúsculo, indica a composição do mínimo com o máximo local.
ν	Letra grega Nu, indica o limiar da força balão.
∇	Símbolo grego Nabla, denomina o operador diferencial.
$\in$	Símbolo que indica a relação de pertinência.

Sumário

1	INTRODUÇÃO	27
1.1	Motivação para a Dissertação	29
1.2	Descrição do problema	29
1.3	Objetivos Geral e Específicos	30
1.4	Produção científica	30
1.5	Estrutura da Dissertação	32
2	TRABALHOS RELACIONADOS	33
2.1	Métodos de Contornos Ativos	33
2.1.1	MCA Balão	34
2.1.2	MCA <i>Gradient Vector Flow</i> (GVF)	35
2.1.3	MCA <i>Vector Field Convolutional</i> (VFC)	36
2.1.4	MCA THR-multi e MCA THR-mod	37
2.1.5	MCA Crisp	38
2.1.6	MCA Crisp Adaptativo (CRAD)	40
2.1.7	MCA <i>Optimum path Snakes</i> (OPS)	41
2.2	Level Set	42
2.3	Contorno Ativo Geodésico Tradicional.	43
2.3.0.1	Detector de borda tradicional	44
2.3.0.2	Operador de curvatura	44
2.4	SISDEP	46
2.5	Deteção automática da curva de inicialização	46
2.6	Medidas de avaliação	50
3	METODOLOGIA	53
3.1	Uma abordagem morfológica para o contorno ativo geodésico	53
3.2	Detector difuso de fronteira	56
3.3	Deteção automática do Level Set inicial	62
3.3.1	Pré-Processamento	62
3.3.2	Deslocamento de Contraste	63
3.3.3	Deteção das componentes de inicialização	65
3.3.4	Reconstrução Morfológica	67
3.4	Aquisição das Imagens Médicas	70
4	RESULTADOS	71
4.1	Metodologia de avaliação	71

4.2	Análise dos resultados	72
5	CONCLUSÃO	81
6	ANEXO A	84
	REFERÊNCIAS	85

1 Introdução

Patologias pulmonares estão entre as principais doenças que causam um número significativo de mortes em todo o mundo. Somente em 2015, houve um aumento de 30% nas taxas de mortalidade causadas pela doença pulmonar obstrutiva crônica (DPOC). A Organização Mundial da Saúde (OMS) (WHO, 2018) registrou cerca de 3 milhões de mortes devido à DPOC, representando 5% de todas as mortes registradas naquele ano.

A fibrose pulmonar, por outro lado, ainda apresenta causas desconhecidas e média de sobrevida estimada entre 2 a 4 anos após o diagnóstico (PNEUMOLOGIA, 2019). No Brasil a incidência anual dos casos chega a 5,1 para cada 100 mil habitantes (BADDINI-MARTINEZ; PEREIRA, 2015). Neste sentido, o exame de tomografia computadorizada de alta resolução apresenta-se como o mais indicado em protocolos de diagnósticos precoces (CAPITAL et al., 2018).

Doenças como a DPOC são caracterizadas por uma redução progressiva do fluxo respiratório causada por bronquite crônica ou enfisema, obstruindo o espaço aéreo pulmonar e reduzindo a oxigenação. Já fibrose pulmonar causa uma diminuição progressiva na elasticidade do pulmão, diminuindo a captação de oxigênio e causando a falta de ar. Deste modo, pesquisas no campo da pneumologia têm importância significativa para detectar a capacidade de ventilação pulmonar e fomentar o diagnóstico precoce (PAUWELS et al., 2012).

O uso de imagens médicas é amplamente difundido para a aquisição e representação de informações do corpo humano, a tomografia computadorizada (TC) do tórax, em especial, é uma das técnicas que se destacam na avaliação dos distúrbios pulmonares (NÓBREGA; RODRIGUES; FILHO, 2017). Diagnósticos a partir deste exame podem ser melhorados por meio de sistemas de auxílio ao diagnóstico médico, como as técnicas de segmentação para encontrar a região de interesse na imagem. No caso das imagens médicas, é comum aplicar métodos de segmentação para identificar características nas estruturas fisiológicas e associa-las ao estudo de patologias.

Entre as técnicas aplicadas estão a morfologia matemática (MEDEIROS; FERREIRA, 2015), o crescimento de regiões com limiares locais (FELIX et al., 2009), assim como a transformada *watershed* (AVINASH; MANJUNATH; KUMAR, 2016) para a segmentação do pulmão. No entanto, segundo Rebouças Filho et al. (REBOUÇAS FILHO et al., 2014), técnicas tradicionais não costumam obter uma segmentação consistente para regiões pulmonares de baixo contraste, e também sofrem com a influência das estruturas internas levando a resultados inadequados quando aplicados em exames de TC.

Assim, para superar essas limitações, Métodos de Contornos Ativos (MCA), também

conhecido como *Snakes*, têm se destacado especialmente em aplicações em imagens médicas por apresentar um potencial adaptativo na segmentação mesmo quando na presença de baixo contraste (REBOUÇAS FILHO, 2010; REBOUÇAS FILHO et al., ; REBOUÇAS FILHO et al., 2017a; MEDEIROS et al.,). A vantagem dos modelos deformáveis baseados em MCA é a sua capacidade de adaptação às mudanças de energias provenientes das estruturas na imagem.

Tradicionalmente, os MCAs baseiam-se em segmentos de linha que evoluem formando uma curva no domínio da imagem. A curva se adapta de acordo com a forma da região ao redor do ponto inicial e se desenvolve até os limites do objeto de interesse (KASS; WITKIN; TERZOPOULOS, 1988). Vários métodos baseados em contornos ativos têm sido propostos na literatura, visando segmentar corretamente as imagens pulmonares. No entanto, a maioria desses métodos depende fortemente da influência de energias externas e são baseados em processos iterativos para atualizar cada ponto da curva de inicialização (REBOUÇAS FILHO et al., 2017b), o que pode tornar o processo de segmentação lento.

O método de Fluxo de Vetor de Gradiente (GVF), descrito por Xu e Prince (1998), por exemplo, é limitado às regiões côncavas e homogêneas, em que o gradiente tende a ser nulo. A Convolução de Campo Vetorial (VFC), proposta por Li e Acton (2006), sofre com mudanças na topologia onde a borda do objeto de interesse não é uniforme. Por outro lado, ACM Crisp, proposto por REBOUÇAS FILHO (2010) depende da localização do ponto de partida, e pode levar a problemas de convergência precoce.

A fim de superar estes desafios, o Método de Contorno Ativo Geodésico (GAC, do inglês *Geodesic Active Contour*) proposto por Caselles et al. (CASELLES; KIMMEL; SAPIRO, 1997) tem apresentado resultados relevantes em estudos recentes na literatura (RAPAKA; KUMAR, 2018). Assim, inspirado no GAC, este trabalho apresenta o MCA geodésico morfológico rápido (FGAC, do inglês *Fast morphological Geodesic Active Contour*) como uma nova abordagem para segmentação de pulmão baseada em contorno ativo geodésico sob uma perspectiva da morfologia matemática e livre de algoritmos supervisionados para classificação.

Combinado ao FGAC, apresentamos um mecanismo de inicialização automática que detecta uma curva inicial para cada pulmão, com morfologia em estágios avançados de evolução, muito próxima a região de interesse, o que acelera a convergência da curva de segmentação. Como uma evolução do detector de borda tradicional do GAC proposto por Caselles, Kimmel e Sapiro (1997), na construção do FGAC também apresentamos um novo detector difuso de fronteira que visa corrigir patologias apresentadas pela abordagem tradicional, especialmente aplicada a regiões próximas às bordas do pulmão, visando assim um melhor desempenho na segmentação do exame de TC do tórax.

1.1 Motivação para a Dissertação

Diferentes abordagens têm sido propostas na literatura para segmentação da região pulmonar em imagens de tomografia computadorizada, entretanto, a evolução dos métodos de contornos ativos tem visado especialmente o cálculo de novas energias, que, em geral, não consideram a morfologia da região de interesse, outras abordagens sugerem a combinação de classificadores, o que pode tornar o processo de segmentação dispendioso.

Por outro lado, a representação por meio de equações explícitas da curva de segmentação também torna oneroso o processo de evolução da curva, uma vez que processos iterativos costumam ser utilizados para atualizar individualmente os pontos. Estratégias inspiradas nas mudanças topológicas da imagem possibilitam a adaptação da curva de forma implícita, embutido-a em formas geométricas que são deformáveis, oferecendo assim uma estratégia simples e de convergência rápida.

1.2 Descrição do problema

Imagens de Tomografia Computadorizada do tórax apresentam diferentes características topológicas e de contraste. Segundo REBOUÇAS FILHO et al. (2017b), há diferentes estruturas internas ao tórax cuja representação no exame é definida pela densidades do tecido, o que afeta diretamente o contraste da parede pulmonar e das vias respiratórias. Apresentando regiões aproximadamente simétricas e separadas por pequenas fissuras (Figura 1.a), com concavidades e baixo contraste (Figura 1.b) ou afetadas por patologias que alteram a densidade do tecido (Figura 1.c).




Figura 1 – Amostras de pulmões com diferentes configurações topológicas e de contraste.

Diante deste cenário, a construção de métodos para segmentação do pulmão deve contemplar estes detalhes, de forma que a região de interesse não seja afetada ao final da segmentação. Caselles, Kimmel e Sapiro (1997) originalmente apresentam um modelo deformável inspirado nas curvas geodésicas, cuja representação implícita da curva possibilita uma adaptação às diferentes topologias.

Superar estes desafios também requer um tempo aceitável ao processo de segmentação. Neste aspecto, a inovação deste trabalho está no desenvolvimento de uma solução simples de rápida convergência, inspirada na morfologia da região pulmonar e como uma

evolução dos trabalhos de Caselles, Kimmel e Sapiro (1997), oferece um processo com inicialização automatizada que permite a segmentação simultânea dos dois pulmões.

1.3 Objetivos Geral e Específicos

Como a tarefa de segmentação de pulmões exige um cuidado às mudanças topológicas bem como aos diferentes contrastes apresentados, o modelo de segmentação proposto apresenta-se como uma ferramenta poderosa para o uso em sistemas que auxiliam o diagnóstico clínico na análise de Tomografia Coputadorizada do tórax. Visa, portanto, oferecer uma solução adaptativa àquelas restrições, de forma automática, simples, rápida e independente de algoritmos de classificação que podem impor restrições de tempo ao projeto.

Este trabalho se concentra nos seguintes objetivos específicos:

1. Comparar desempenho de outros métodos de segmentação especializados em pulmonologia;
2. Avaliar diferentes parâmetros da solução, entre eles a curva inicial e os parâmetros de suavização do gradiente, visando encontrar uma segmentação com maior similaridade às marcações manuais do humano especialista;
3. Propor mecanismo de detecção de bordas adaptável às diferenças de contraste internas e próximas às fronteiras dos pulmões;
4. Desenvolver um mecanismo de inicialização adaptável às diferentes morfologias pulmonares;
5. Desenvolver uma abordagem de segmentação da região pulmonar independente de algoritmo de classificação e com baixo custo de tempo;
6. Produzir um banco de imagens segmentadas com o método proposto para fomentar pesquisas futuras.

1.4 Produção científica

Durante este projeto de mestrado, os seguintes trabalhos científicos foram aceitos e publicados, a saber:

- **MEDEIROS, ALDISIO G.**; GUIMARÃES, M. T. ;PEIXOTO, S. A.; SANTOS, L. O.; BARROS, ANTONIO CARLOS. S. ; REBOUÇAS, E.S; DE ALBUQUERQUE, VICTOR HUGO C. ; REBOUÇAS FILHO, PEDRO PEDROSA. New Fast Morphological Geodesic Active ContourMethod for Lung CT Image

- Segmentation. Journal of the International Measurement Confederation, v.55, 2019. (Qualis A1 Eng.IV)
- **MEDEIROS, ALDISIO. G.** ; PEIXOTO, S. A.; BARROS, A. C. S. ; ALBUQUERQUE, V. H. C. ; Rebouças Filho, Pedro Pedrosa . Uma nova abordagem para a segmentação de pulmões utilizando o método de contorno ativo não paramétrico Optimum Path Snakes em imagens de tomografia computadorizada. In: 17 Workshop de Informática Médica (WIM), 2017, São Paulo. Workshop de Informática Médica (WIM), 2017. v. 17. (Qualis B4 C.C.)
 - VASCONCELOS, F. F. X.; **MEDEIROS, ALDISIO G.**; PEIXOTO, S. A.; REBOUÇAS FILHO, P. P. Automatic skin lesions segmentation based on a new morphological approach via geodesic active contour. Cognitive Systems Research, v.55, p. 44-59, 2019. (Qualis B1 C.C.)
 - PEIXOTO, SOLON A; **MEDEIROS, ALDISIO G.**; BARROS, ANTONIO CARLOS. S. ; DE ALBUQUERQUE, VICTOR HUGO C. ; REBOUÇAS FILHO, PEDRO PEDROSA . A New Approach to Segment Hemorrhagic Stroke in Computed Tomography via Optimum Path Snakes. In: 2017 16th IEEE International Conference on Machine Learning and Applications (ICMLA), 2017, Cancun. (Qualis B1 C.C.)
 - Rebouças Filho, Pedro Pedrosa; PEIXOTO, S. A.; Nóbrega, Raul Victor M. ; HEMANTH, D. J. ; **MEDEIROS, ALDISIO. G.**; SANGAIAH, A. K. ; ALBUQUERQUE, V. H. C. Automatic histologically-closer classification of skin lesions. COMPUTERIZED MEDICAL IMAGING AND GRAPHICS, v. 68, p. 40-54, 2018. (Qualis A2 C.C.)
 - DA SILVA, SUANE PIRES P ; DA NOBREGA, RAUL VICTOR M ; **MEDEIROS, ALDISIO G.** ; MARINHO, LEANDRO B. ; ALMEIDA, JEFFERSON S. ; FILHO, PEDRO PEDROSA REBOUCAS. Localization of Mobile Robots with Topological Maps and Classification with Reject Option using Convolutional Neural Networks in Omnidirectional Images. In: 2018 International Joint Conference on Neural Networks (IJCNN), 2018, Rio de Janeiro. 2018 International Joint Conference on Neural Networks (IJCNN), 2018. p. 1. (Qualis A1 C.C.)

Como produção relacionada, o seguinte trabalho foi submetido para avaliação. Em uma aplicação para detecção de acidente vascular cerebral em exames de tomografia do crânio:

- **MEDEIROS, ALDISIO G.**; SANTOS, L. O.; SARMENTO, R. M.; DE ALBUQUERQUE, VICTOR HUGO C.; REBOUÇAS FILHO, PEDRO PEDROSA. New Fast Morphological Geodesic Active Contour Method for Segmentation of Hemorrhagic Stroke in computed tomography image. Medical and & Biological Engineering & Computing, v.57, 2019. (Qualis A1 Eng. IV)

1.5 Estrutura da Dissertação

Este trabalho apresenta no Capítulo 2 uma revisão dos métodos de contornos ativos especializados em segmentação pulmonar, desde o contorno ativo tradicional até os mais recentes baseados em energias adaptativas. Além disso, são exploradas técnicas recentes de inicialização de contornos ativos que deram base ao desenvolvimento do método proposto. No Capítulo 3, apresentamos a nova abordagem de segmentação, explorando desde o contorno geodésico tradicional, passando por equivalências dos operadores morfológicos até a proposição do FGAC. Por fim, discutimos os resultados no Capítulo 4 e as conclusões e trabalhos futuros no Capítulo 5.

2 Trabalhos relacionados

Este capítulo apresenta o estado da arte dos algoritmos de segmentação baseados em modelos deformáveis. Descrevendo a evolução de algoritmos inspirados em métodos de contornos ativos (MCA), desde a criação do modelo tradicional até os métodos recentes baseados em energias adaptativas como é o caso do Crisp Adaptativo (CRAD) (REBOUÇAS FILHO, 2013) e, mais recentemente, o *Optimum Path Snakes* (BARROS, 2016). Estes conceitos contribuem para a fundamentação teórica do FGAC.

2.1 Métodos de Contornos Ativos

Inicialmente, Kass, Witkin e Terzopoulos (1988) propuseram o método de contorno ativo baseado em modelos deformáveis, onde o objetivo é adaptar uma curva inicial ao formato de uma região de interesse. A curvatura ocorre por intermédio de forças que atuam deformando a curva, evoluindo-a até as bordas do objeto. A deformação é guiada pela minimização do funcional de energia E , que em seu formato discreto pode ser descrito como:

$$E = \sum_{p=0}^{N-1} \{E_{int}[c(p)] + E_{ext}[c(p)]\}, \quad (2.1)$$

onde c representa uma curva inicial, N é o comprimento total da curva e $c(p)$ é um ponto em c , nas coordenadas x e y :

$$c(p) = [x(p), y(p)] \quad (2.2)$$

Quanto às energias envolvidas, têm-se a energia interna $E_{int}[c(p)]$, que depende das características internas à curva de segmentação e pode ser descrita como:

$$E_{int}[c(p)] = \alpha(p)c'(p) + \beta(p)c''(p), \quad (2.3)$$

onde α e β são valores que ponderam a evolução em um ponto p da curva, regendo a elasticidade e a curvatura. Ambas as forças são ajustadas de acordo com a primeira e segunda derivadas, respectivamente. Em que a elasticidade diz respeito à propriedade dos pontos se distanciarem uns dos outros, permitindo a expansão da curva. Já a curvatura diz respeito à flexibilidade dos segmentos de reta, permitindo acentuar ou reduzir os ângulos internos.

Por outro lado, a energia externa $E_{ext}[c(p)]$ pode ser representada por características presentes na imagem, externas à curva. Nixon e Aguado (2012) sugerem calcular a energia externa a partir do resultado de um operador de gradiente como o Sobel, em que a energia externa pode ser identificada avaliando linhas, segmentos e terminações.

Portanto, a energia E é capaz de guiar a expansão ou a contração da curva, evoluindo-a até a região de fronteira do objeto de interesse. Contudo, a abordagem tradicional não mostrou-se suficiente para tratar problemas de inicialização longe das bordas e próxima a regiões uniformes. Nestas áreas há uma baixa influência do gradiente devido a pouca variação das intensidades, a energia externa tende a ser nula induzindo maiores influências apenas da energia interna, o que pode levar ao colapso precoce da curva em um único ponto (REBOUÇAS FILHO, 2010; REBOUÇAS FILHO et al., 2017).

Neste aspecto, surgem novos métodos adicionando novas energias para contornar as limitações do MCA tradicional. A literatura apresenta diferentes métodos e aqui destacamos o Gradient Vector Flow (GVF) de Xu e Prince (1998), o Vector Field Convolution (VFC) de Li e Acton (2006), os MCAs baseados na transformada de Hilbert (THR-mod e THR-multi) de Félix (2011), o método Crisp proposto por REBOUÇAS FILHO (2010), além das abordagens mais recentes como Crisp Adaptativo (CRAD) de REBOUÇAS FILHO et al. (2013) e *Optimum path Snakes* (OPF) de Barros (2016). Além dos métodos baseados em contornos ativos, destacamos também o Sistema para a Detecção e a quantificação de Enfisema Pulmonar (SISDEP) proposto por FELIX (2007), formando um conjunto de métodos baseados em técnicas tradicionais mas também em classificação supervisionada, como descrevemos nas seções a seguir.

2.1.1 MCA Balão

Como visto, a abordagem tradicional apresentou limitações, especialmente em situações onde a inicialização acontece distante das bordas. Mostrando-se fortemente sensível à ausência de gradiente. Na tentativa de contornar este problema, Cohen (1991) adiciona uma nova força interna chamada Força Balão (F_{ballon}).

A força F_{ballon} é incorporada à força de continuidade (Equação 2.3), evoluindo o cálculo da energia interna. A nova força atua, portanto, expandindo a área da curva inicial, movendo a curva até as regiões onde há influência de gradientes oriundos das bordas do objeto. Mackiewicz (1995) sugere a implementação da Força Balão como um vetor no sentido oposto ao baricentro da curva em evolução, evitando assim a convergência precoce em áreas uniformes.

Entretanto, a F_{ballon} apresenta limitações quando o contorno ativo é inicializado em regiões descentralizadas. Por ser baseada no vetor oposto ao baricentro da curva, a concavidade atenua a influência do vetor e a evolução dos pontos estabiliza, convergindo antes do esperado. Isto evidencia sua baixa adaptação às mudanças topológicas na imagem. Este comportamento é ilustrado na Figura 2, de (a) até (d) uma evolução com inicialização no centro, já de (e) até (h) representa uma inicialização próxima a região côncava.




Figura 2 – Exemplos de inicialização do MCA Balão. (a) até (d) representa a evolução com inicialização no centro do objeto; (e) até (h) representa uma evolução com inicialização próxima a região côncava, com convergência precoce. Em todos os casos as setas representam a influência da F_{ballon} .

2.1.2 MCA Gradient Vector Flow (GVF)

Visando superar as limitações do MCA Balão que causam a convergência precoce da evolução da curva, Xu e Prince (1998) propõem uma nova abordagem de MCA baseada na expansão do fluxo gradiente da imagem, chamado de MCA *Gradient Vector Flow* (GVF). Este método utiliza vetores de gradiente para adaptar o comportamento da curva em regiões com contornos de baixa definição.

O MCA GVF é construído sobre um campo de vetores, este campo é definido a partir do fluxo do gradiente proveniente das regiões de borda do objeto. Os vetores apontam no mesmo sentido onde ocorre a maior variação de intensidades. Nesta abordagem, o MCA GVF utiliza a energia interna proposta no MCA tradicional e propõe uma nova energia externa que é proporcional ao ∇f , sendo f a imagem a ser segmentada então ∇f é o vetor gradiente de f .

A evolução da curva é feita de forma iterativa, minimizando a energia funcional E_{gvf} definida pelas funções u e v que calculam as derivadas parciais sobre as coordenadas x e y :

$$E_{gvf} = \int \int \mu \left(\frac{\partial u^2}{\partial x} + \frac{\partial u^2}{\partial y} + \frac{\partial v^2}{\partial x} + \frac{\partial v^2}{\partial y} \right) + |\nabla f|^2 |w - \nabla f|^2 dx dy, \quad (2.4)$$

onde w é o fluxo de gradiente definido por $w(x, y) = [u(x, y), v(x, y)]$, já o parâmetro μ permite ajustar o equilíbrio entre os dois termos e rege a influência do campo de fluxo gradiente.

Contudo, o MCA GVF também apresenta limitações quando inicializado próximo a regiões descentralizadas. Segundo REBOUÇAS FILHO et al. (2013), o MCA GVF resolve os problemas de inicialização longe das bordas e próximo a regiões homogêneas, mas somente quando inicializado fora da região do objeto. A evolução da curva, portanto,

continua dependendo do campo de gradiente, sendo atraída para onde há um maior fluxo. Porém, nas regiões distantes da borda o campo de vetores não é suficiente para continuar a expansão da curva e uma convergência incompleta pode ser obtida.

A Figura 3 ilustra, de (a) até (d) uma evolução com inicialização no centro, com convergência satisfatória, já de (e) até (h), com inicialização descentralizada, percebe-se que o campo do fluxo de gradiente não é suficiente para atrair a curva até a borda.




Figura 3 – Exemplos de inicialização do MCA GVF. (a) até (d) representa a evolução com inicialização no centro do objeto; (e) até (h) representa uma evolução com inicialização descentralizada próxima a borda, com convergência precoce. Em todos os casos as setas representam a influência do campo de fluxo gradiente.

Além disto, estudos anteriores (REBOUÇAS FILHO et al., 2013; REBOUÇAS FILHO, 2010) avaliam que o processo iterativo do MCA GVF para a geração do campo de fluxo gradiente apresenta um custo computacional significativo, chegando a ser 30 vezes mais lento que o MCA Balão e tradicional, impondo deste modo uma limitação para aplicações com restrição de tempo.

2.1.3 MCA *Vector Field Convolutional* (VFC)

Por outro lado, Li e Acton (2006) propõem um novo MCA baseado nas energias internas do MCA tradicional, apresentando uma nova energia externa baseada na convolução entre o campo de vetores $k_{vfc}(x, y)$ com o mapa de bordas $f_{vfc}(x, y)$, o resultado desta convolução é uma imagem $I(x, y)$ que representa a nova energia externa E_{vfc} .

O campo de vetores pode ser dado como $k_{vfc}(x, y) = m_k(x, y)n_k(x, y)$, onde $m_k(x, y)$ é a magnitude do vetor na posição (x, y) e $n_k(x, y)$ é o vetor unitário para a origem do núcleo. Conforme descrito por Li e Acton (2006), o vetor do núcleo pode ser dado por $n_{vfc}(x, y) = [-\frac{x}{r}, -\frac{y}{r}]$, em que r é o raio do núcleo em relação a origem, em que $n(0, 0) = [0, 0]$. Finalmente, a nova energia externa E_{vfc} é descrita por:

$$E_{vfc} = k_{vfc}(x, y) * f_{vfc}(x, y) \quad (2.5)$$


A grande vantagem apresentada pelo MCA VFC é o seu custo computacional reduzido em comparação ao MCA GVF. Por outro lado, diferentemente dos métodos anteriores, o MCA VFC também apresenta uma redução na sensibilidade quanto a posição de inicialização da curva, além da robustez quando submetido a imagens com ruídos gaussianos e impulsivos.

Contudo, o MCA VFC falha quando não há uma boa definição do contorno do objeto de interesse. Especialmente quando há dois objetos próximos, um com bordas bem definidas e de alta intensidade e outro com bordas descontínuas e de baixa intensidade. Para estes casos o VFC ultrapassa o objeto de interesse, aquele com as bordas de baixa intensidade, evoluindo a curva até as bordas de alta intensidade do segundo objeto, resultando em uma segmentação indesejada.

2.1.4 MCA THR-multi e MCA THR-mod

Ao longo da evolução dos MCAs, o cálculo da energia externa tem sido amplamente investigado na literatura. Abordagens tradicionais para detecção de bordas, tais como operadores de Roberts, Prewitt, Sobel e Laplaciano apresentam sensibilidade em imagens ruidosas e com bordas irregulares (REBOUÇAS FILHO, 2010; GONZALEZ, 2009). Neste sentido, transformações cujo comportamento muda quando ocorrem oscilações na intensidade do sinal apresentam-se como uma alternativa aos detectores tradicionais.

A transformada de Hilbert (TH), em especial, possui características peculiares na detecção de oscilações abruptas em sinais, indicando picos de oscilação quando há variação de intensidades (ALEXANDRIA et al., 2014; REBOUÇAS FILHO, 2013). Um exemplo deste comportamento é ilustrado na Figura 4, onde um sinal ruidoso $f(t)$ é processado pela TH $\hat{f}(t)$, ambos sinais estão representados em 1D.



(a) Fonte: adaptado de Alexandria et al. (2014)

Figura 4 – Transformada de Hilbert aplicada a um sinal ruidoso 1D (f). Os picos em $\hat{f}$ indicam as transições do sinal.

Partindo deste princípio, Davis et al. (2000) propõem a Transformada de Hilbert Radial (THR), sendo definida como:

$$THR(x, y) = TFI_{2D}\{exp(j \cdot n \cdot \theta) \cdot TF_{2D}[g(x, y)]\}, \quad (2.6)$$

onde $\theta = \cos^{-1}(\frac{\omega}{r}) = \sin^{-1}(\frac{s}{r})$, $r = (\omega^2 + s^2)^{1/2}$, ω e s são variáveis no domínio da frequência, $j \in \mathbb{C}$ e $n \in \mathbb{Z}$. TF e TFI são as Transformada de Fourier e a Transformadas de Fourier Inversa, respectivamente.

Posteriormente, FELIX (2013) propõe 6 diferentes tipos de MCA com energias externas inspiradas na THR. Os MCAs utilizam a energia interna do MCA tradicional combinada com a energia proveniente da THR, e busca a minimização da função descrita por:

$$v_t(s, t) = \alpha[\mu'(s, t)] - \beta[\mu''(s, t)] + E_{THR}[v(s, t)], \quad (2.7)$$

em que s é substituído por (x, y) , α e β são pesos para a primeira e segunda derivadas, respectivamente. A energia externa $E_{THR}(x, y) = THR(x, y)$ é obtida pela aplicação direta da equação 2.6.

Destacamos aqui dois modelos: THR multidirecional (MCA THR-multi) e o THR módulo multidirecional (MCA THR-mod). O MCA THR-multi realiza o cálculo da energia externa em quatro direções para θ , assumindo os valores iguais a 0° , 60° , 90° e 120° . Segundo REBOUÇAS FILHO (2013), a utilização destas quatro direções permite a captura de regiões côncavas que contribuem para minimizar falhas nestas regiões.

Por outro lado, o MCA THR-mod altera o cálculo da energia, possibilitando que a energia externa amplie a informação da borda. Para evitar que a nova energia cause o aparecimento de vetores ruidosos, que podem conduzir a uma convergência errada de sua curva, aplica-se o filtro gaussiano $G_\sigma(x, y)$ para reduzir a influência de tais vetores, portanto, a energia do MCA THR-mod pode ser calculada por:

$$E_{THR}(x, y) = [|THR(x, y)|]^2 * G_\sigma(x, y) \quad (2.8)$$

2.1.5 MCA Crisp

Os MCAs vistos anteriormente propõem a utilização de novas energias visando melhorar o desempenho do MCA tradicional. Todavia, estes métodos consideram em suas abordagens o cálculo de gradiente tradicional, desconsiderando, em especial, as estruturas internas do parênquima pulmonar, tais como vasos, vias aéreas e parede pulmonar, ao serem representados na imagem, podem gerar falsas bordas e confundir a evolução da curva (REBOUÇAS FILHO, 2013).

Visando superar estas limitações, REBOUÇAS FILHO (2010) propuseram o MCA Crisp inspirado na densidade dos tecidos pulmonares para estabelecer faixas de análise na

imagem. As faixas definidas no MCA Crisp são baseadas em unidades Hounsfield (UH) distribuídas em: áreas hiperaeradas, -1000 a -950 UH, normalmente aeradas, -950 a -500 UH, pouco aeradas, -500 a -100 UH, não aeradas, -100 a 100 UH, e região óssea, 600 a 2000 UH.

Com base nas faixas de densidade, o MCA Crisp incorpora uma nova energia externa E_{crisp} ao MCA balão desenvolvido por Mackiewicz (1995). A energia E_{crisp} é definida pelos percentuais de cada região presentes na imagem. Neste caso, cada faixa representa um tipo de região, adiciona-se também uma região como área não classificada, compondo assim 6 classes u_i , $i \in [0; 5]$.

REBOUÇAS FILHO (2010) propõe uma matriz de densidades $D(x, y)$, e que (x, y) representam as coordenadas na imagem. Sob a análise da vizinhança 9x9, a função que define a quantidade de pontos com densidades presente em cada classe u_i é descrita por (REBOUÇAS FILHO, 2010):

$$f(x, y, u_i) = \sum_{l=-4}^4 \sum_{m=-4}^4 R(x-l, y-m), \quad (2.9)$$

no qual

$$R(x, y) = \begin{cases} 1, \lim_{inf}(u_i) \leq D(x, y) < \lim_{sup}(u_i) \\ 0, \text{ caso contrário} \end{cases} \quad (2.10)$$

onde $\lim_{inf}(u_i)$ e $\lim_{sup}(u_i)$ são os limites inferior e superior da faixa de densidades, em UH, para a classe u_i . Deste modo, é possível calcular o percentual P_i de cada classe i :

$$P_i = \frac{f(x, y, u_i)}{\sum_{j=0}^4 f(x, y, u_j)} \quad (2.11)$$

A classe 5 é desconsiderada por representar áreas não classificadas. Finalmente, E_{crisp} é dada por (REBOUÇAS FILHO, 2010) como:

$$E_{crisp}(x, y) = \begin{cases} 0, \text{ para } P_3 < 0,2 \text{ e } P_4 < 0,15, \\ S(x, y), \text{ caso contrário} \end{cases} \quad (2.12)$$

em que $S(x, y)$ é o operador Sobel, e os limiares 0.2 e 0.15 são obtidos de forma empírica.

Baseado nas faixas de densidade, o MCA Crisp também utiliza uma inicialização automática, denominada $Crisp_{inicial}$ e pode ser consultada, em maiores detalhes, no trabalho de (REBOUÇAS FILHO, 2010). O método incorpora heurísticas quanto ao conhecimento prévio das faixas de intensidades em relação às unidades UH, além disso, embora inove na análise por densidade, por ser baseado no MCA Balão herda a patologia de inicialização interna em regiões descentralizadas e sofre com as mudanças de topologia na imagem (REBOUÇAS FILHO, 2013), como concavidades, e pode conduzir a curva a uma segmentação incompleta.

2.1.6 MCA Crisp Adaptativo (CRAD)

Como uma evolução do MCA Crisp, REBOUÇAS FILHO (2013) propôs o MCA Crisp Adaptativo (CRAD) como uma alternativa às limitações observadas na aplicação do MCA Crisp, proposto por REBOUÇAS FILHO (2010), tais como inicializações descentralizadas e internas a região de interesse. Nesta abordagem, o MCA CRAD altera a energia externa substituindo a força Balão proposta por Mackiewicz (1995) por uma nova força balão adaptativa, além disso, substitui a energia E_{crisp} por uma versão adaptativa chamada E_{crad} .

As duas novas energias propostas pelo MCA CRAD definem uma nova energia que rege a evolução da curva de segmentação. Neste sentido, a energia total, em um ponto $c(s)$ da curva, é definida por REBOUÇAS FILHO (2013) como E_{CRAD} :

$$E_{CRAD}[c(s)] = E_{int_{adap}}[c(s)] + E_{ext_{CRAD}}[c(s)], \quad (2.13)$$

onde $E_{int_{adap}}$ é a energia interna adaptativa e $E_{ext_{CRAD}}$ é a energia externa Crisp Adaptativa.

A força Balão Adaptativa utiliza informações da topologia da curva para expandir o contorno. Estas informações são específicas para cada ponto e partem do princípio que a curva possui formatos distintos ao longo de sua topologia. Deste modo, a força Balão Adaptativa desloca cada ponto da curva de maneira distinta em direção às bordas do objeto de interesse, adaptando-se à região em que está inserido.

Neste aspecto, de acordo com REBOUÇAS FILHO (2013), a energia $E_{int_{adap}}$ é definida como:

$$E_{int_{adap}} = w_{cont}F_{cont}[c(s)] + w_{adap}F_{adap}[c(s)], \quad (2.14)$$

em que a primeira componente é a mesma força de continuidade utilizada pelo MCA tradicional proposta por Kass, Witkin e Terzopoulos (1988), já a segunda componente $F_{adap}[c(s)]$ é a nova força Balão Adaptativa e os parâmetros w_{cont} e w_{adap} são pesos associados a cada força. No cálculo dessa nova força interna, as informações utilizadas sobre a topologia de cada ponto são geradas a partir de duas informações. A primeira é obtida com base nas coordenadas de seus vizinhos imediatos e a segunda se baseia na forma geral da curva.

Já em relação à energia externa, o MCA Crisp apresentou limitações em que algumas estruturas internas do pulmão, como hilo e vasos internos, eram classificadas erroneamente como borda do pulmão. Já o MCA CRAD propôs a energia externa $E_{ext_{CRAD}}[c(s)]$, incorporando uma RNA¹ MLP, como algoritmo de classificação supervisionado, para determinar a origem de cada borda encontrada em imagens de TC do tórax. As saídas da

¹ Sigla para Rede Neural Artificial.

etapa de classificação indicam se as bordas encontradas em imagens de TC do tórax são ou não das paredes pulmonares. A energia externa é então definida como:

$$E_{ext_{CRAD}}(x, y) = \begin{cases} S(x, y), & \text{para } f_{mlp}(u) = 1, \\ 1, & \text{caso contrário,} \end{cases} \quad (2.15)$$

em que $S(x, y)$ é o operador Sobel, e u é o vetor de percentuais das classes de densidades.

2.1.7 MCA *Optimum path Snakes* (OPS)

Segundo Barros (2016), um ponto $c(p)$ é capaz de analisar a vizinhança e determinar o caminho ótimo para encontrar o objeto de interesse. Por esta razão, em sua abordagem cada ponto da curva c é chamado de ponto explorador. Como uma metáfora, o ponto explorador é o elemento que sabe onde está e sabe o que está procurando, mas não sabe o que irá encontrar no trajeto de locomoção até o objeto desejado.

Dessa forma, a técnica é inspirada no classificador Floresta de Caminhos Ótimos (OPF), descrito originalmente por Papa, Falcao e Suzuki (2009), e analisa a vizinhança de cada ponto da curva através de uma árvore de menor espalhamento. Cada nó da árvore de caminhos ótimos define uma classe denominada de protótipo que é utilizada para a classificação das amostras, onde o protótipo é sempre o ponto atual do ponto explorador e as amostras são a vizinhança em análise.

O MCA OPS define uma nova energia total que pode ser representada por

$$E_{OPS}[c(p)] = E_{int_{OBA}}[c(p)] + E_{ext_{OP}}[c(p)], \quad (2.16)$$

onde o termo $E_{int_{OBA}}[c(p)]$ descreve a nova energia interna ótima para determinar o trajeto mais eficaz para que um ponto explorador possa expandir sua curva atual, definindo assim uma força interna denominada balão adaptativa, F_{OBA} .

Na Figura 5, é apresentada uma curva sob a aplicação da F_{OBA} , com a expansão dos pontos A e F , a partir do ponto médio dos vizinhos, M_{OB} e M_{EG} . Os pontos na região em vermelho, por serem internos à curva, isto é, já explorados, recebem um custo elevado de forma a evitar a exploração em uma região já visitada. Já a energia externa, $E_{ext_{OP}}[c(p)]$, é definida pelo conhecimento que guia cada ponto explorador, este conhecimento é adquirido através do classificador OPF combinado com um extrator de características ², é, portanto, descrita como

$$E_{ext_{OP}}[c(p)] = \begin{cases} 1, & \text{quando a amostra (vizinho) está dentro da curva,} \\ F_{OP}[c(p)], & \text{caso contrário,} \end{cases} \quad (2.17)$$

² Neste trabalho foi considerado o extrator de característica ADTH, definido em (BARROS, 2016), como uma evolução do ADP definido nas equações 2.9, 2.10 e 2.11. Combinado com um kernel de distância Euclidiana.

em que $F_{OP}[c(p)]$ é o custo do protótipo, entre 0 e 1, obtido no treinamento OPF associado à classe dos objetos não desejados. Percorrendo caminhos ótimos das amostras até os protótipos. Definindo, assim, o quão próximo do ponto explorador está do objeto desejado.




Figura 5 – Exemplo de atuação da força balão adaptativa F_{OBA} . Fonte: Adaptado de Barros (2016).

Por ser baseado no classificador OPF, o MCA OPS é definido sob as distâncias euclidiana, manhattan e propõe a utilização da distância Gaussiana, todas podem ser utilizadas como kernel de classificação do OPF.

2.2 Level Set

Para resolver problemas de topologia, Osher e Sethian (1988) propuseram uma solução numérica baseada em contornos implícitos³ chamada Level Set. Em que a curva de segmentação originalmente paramétrica é representada sob uma superfície, transformando o problema em um modelo geométrico.

Considere um espaço bidimensional, imagine que neste espaço existem duas regiões e que há entre elas uma fronteira. Suponha $C(x, y)$ como uma função que define a fronteira. A ideia do contorno implícito é representar C em uma função ϕ que seja capaz de representar a deformação da fronteira, definindo assim novas posições para os pontos. Para isto, adicionamos uma terceira componente t que representa o tempo. Definimos assim a nova função $\phi[(x, y), t]$ que representa a fronteira. Fazendo a função $\phi[(x, y), t = 0] = C(x, y)$, para o instante inicial temos também uma representação inicial da curva sob a função ϕ , chamamos esta representação inicial de Level Set zero.

A curva $C(x, y)$ passa a ser uma curva de nível embutida no Level Set ϕ . Isso pode ser feito, por exemplo, utilizando uma função de distância com sinal.

$$\phi[(x, y), t] = \begin{cases} -\text{sign}(x, y, C) & , \text{ se } (x, y) \text{ está fora de } C \\ \text{sign}(x, y, C) & , \text{ caso contrário,} \end{cases} \quad (2.18)$$

³ Representações implícitas generalizam a definição da curva, diferentemente das representações explícitas onde a curva é definida ponto a ponto. São úteis para definir contornos fechados.

onde $sign$ denota a distância entre o ponto (x, y) e o ponto mais próximo de C . Nessa representação, uma das vantagens é que não consideramos a parametrização da curva em si, mas a região circunscrita pela curva. Através da manipulação de ϕ que define uma nova fronteira para a curva C , essa modelagem também oferece adaptação às mudanças topológicas, este último caso, porém, é descrito com maiores detalhes no trabalho de Bertuol (2007).

2.3 Contorno Ativo Geodésico Tradicional.

Inspirados na representação em Level Set, Caselles, Kimmel e Sapiro (1997), propuseram o MCA geodésico⁴ (GAC, do inglês *Geodesic Active Contour*). Nesta abordagem, o contorno ativo é baseado na minimização do comprimento da curva por meio do operador de deslocamento por curvatura média.

Considere $I : \mathbb{R}^2 \rightarrow \mathbb{R}$ como uma imagem e $C : \mathbb{R}^+ \times [0, 1] \rightarrow \mathbb{R}^2$ como uma curva paramétrica no tempo, baseado no modelo Level Set de Osher e Sethian (1988) representamos a curva C como uma função embutida na função u , onde $u : \mathbb{R}^+ \times \mathbb{R}^2 \rightarrow \mathbb{R}$ é uma representação implícita de C tal que:

$$C(t) = \{(x, y); u[(x, y), t] = 0\} \quad (2.19)$$

Assim, a evolução da curva C no tempo, ocorre como consequência da aplicação da Equação Diferencial Parcial (EDP) definida como:

$$C_t = F \cdot N \quad (2.20)$$

onde F denota a curvatura em relação ao vetor normal N da curva C . Deste modo, o ajuste da curva C embutida como um Level Set na função $u(x, y)$ é representado por Caselles, Kimmel e Sapiro (1997) em função da variação de u :

$$\frac{\partial u}{\partial t} = F \cdot |\nabla u| \quad (2.21)$$

A evolução da curva embutida no Level Set é definida, portanto, pelo funcional de energia:

$$E(C) = \int_0^{length(C)} g(I)(C(s)) ds \quad (2.22)$$

onde a função $g(I)$ representa o cálculo do gradiente a qual chamaremos aqui de detector de borda. Já a variação de $C(s)$ pode ser dada pela aplicação de um operador de curvatura. Estes parâmetros são descritos a seguir.

⁴ O termo geodésico refere-se à geometria diferencial a qual postula que uma curva geodésica é a menor distância entre dois pontos no espaço riemanniano.

2.3.0.1 Detector de borda tradicional

Tipicamente, o contorno ativo geodésico adiciona um detector de borda $g(I)$ que permite guiar a evolução da curva em relação às bordas do objeto de interesse:

$$g(I) = \frac{1}{\sqrt{1 + \alpha |\nabla G_\sigma * I|}} \quad (2.23)$$

onde $G_\sigma * I$ é um filtro gaussiano com desvio padrão σ , α é um fator de peso. A função $g(I)$ retorna valores cada vez mais baixos quando se aproxima de regiões com alto contraste. Este comportamento nos permite selecionar a região da imagem a qual estamos interessados.

2.3.0.2 Operador de curvatura

A expansão ou a contração da curva ocorre por meio do operador de deslocamento por curvatura média, proposto por Evans, Spruck et al. (1991), fornecendo o grau de curvatura de C :

$$\frac{\partial u}{\partial t} = \text{div} \left(\frac{\nabla u}{|\nabla u|} \right) \cdot |\nabla u| \quad (2.24)$$

onde a curvatura da curva implícita u é dada pela divergência do gradiente normalizado, representado por $\text{div} \left(\frac{\nabla u}{|\nabla u|} \right)$, combinado a variação de u no tempo, $|\nabla u|$.

Como queremos minimizar o funcional de energia (Equação 2.22), baseado na equação de Euler-Lagrange é possível resolver aquela EDP já que esta equação serve de ferramenta para indicar a direção descendente da energia (CASELLES; KIMMEL; SAPIRO, 1997):

$$C_t = (g(I)K + g(I)\nu - \nabla g(I) \cdot N)N \quad (2.25)$$

onde K é a curvatura euclidiana de C , $\nu \in \mathbb{R}$ é o parâmetro da força balão⁵, e N é o vetor normal a curva.

Por fim, substituindo as EDPs 2.23 e 2.24 em 2.25, a evolução da curva para o MCA geodésico, pode ser definida em uma modelagem do tipo Level Set, reescrevendo a Equação 2.25 temos:

$$\frac{\partial u}{\partial t} = g(I)|\nabla u| \left(\text{div} \left(\frac{\nabla u}{|\nabla u|} \right) + \nu \right) + \nabla g(I) \nabla u + g(I) \cdot \nu |\nabla u|, \quad (2.26)$$

onde I é a imagem a ser processada, u é o Level Set, e ν é o parâmetro que define a atuação da força balão.

O deslocamento por curvatura média minimiza o comprimento de arco Euclidiano da curva C , i.e., indica o sentido de minimização do funcional de energia, aproximando

⁵ A força balão é embutida no cálculo para atrair a curva em regiões homogêneas, ν representa um limiar de atuação da força, i.e., a força balão atua até que um gradiente mínimo seja alcançado.

a curva de uma representação da geodésica em um espaço de Riemann. Na Figura 6, é possível observar o resultado da aplicação do operador de curvatura, ilustrado em um objeto de 3 dimensões. Considere os dois pontos de referência, a e b , entre eles existe uma distância representada pela curva na cor amarela. À medida em que se aplica o operador de curvatura, (a) até (d), visando aproximar a curva inicial de uma geodésica, observa-se o aumento da curvatura, a consequência é a deformação da superfície inicial, neste caso, contraindo-a até aproximar-se de uma esfera.

Efeitos semelhantes acontecem quando aplicado em um plano de 2 dimensões. Na Figura 6, de (e) até (h), ilustramos este resultado. É possível observar uma deformação do Level Set (representado pela componente binária branca) cuja consequência é a evolução da curva C (representado pela linha vermelha).




Figura 6 – Aplicação do contorno ativo geodésico combinado com o operador de curvatura. A linha superior representa a evolução em 3D, já na linha inferior em um plano 2D aplicado em uma componente binária representada pela cor branca. Adaptado de Marquez-Neila, Baumela e Alvarez (2014).

O modelo de evolução da curva, definido pelo MCA geodésico não depende, portanto, da análise, ponto a ponto, da curva paramétrica C . O que oferece uma simplificação na construção do MCA. Vale ressaltar que os métodos de integração numérica podem ser usados para resolver a EDP 2.26. Segundo Marquez-Neila, Baumela e Alvarez (2014) a solução do funcional definido na EDP 2.22 pode ser alcançada por meio de esquemas de diferenças finitas. Contudo, estudos recentes indicam que esta técnica é computacionalmente custosa e converge lentamente (MARQUEZ-NEILA; BAUMELA; ALVAREZ, 2014; BERTUOL, 2007). Na seção a seguir, apresentamos uma abordagem baseada em operadores morfológicos para uma evolução rápida, simples e estável ⁶.

⁶ Aqui o termo estável refere-se a ausência de transformações de variáveis contínuas em discretas necessárias às soluções numéricas baseadas em diferenças finitas e que podem levar a instabilidade do valor encontrado como solução do funcional.

2.4 SISDEP

O Sistema para a Detecção e a Quantificação de Enfisema Pulmonar (SISDEP) foi desenvolvido a partir de técnicas de Processamento Digital de Imagens, objetivando reunir ferramentas capazes de: segmentar, de forma precisa e automática, o parênquima pulmonar, incluindo as medidas de área de secção dos pulmões em imagens de tomografia computadorizada de alta resolução (TCAR), densidade pulmonar média (DPM), definindo o percentual de áreas hiperaeradas compatíveis com enfisema - área relativa das unidades de volume (voxels) com densidade < -950 UH, e área relativa (AR) de -950 e os valores de 15º percentil de baixa atenuação (Perc15).

O limiar de -950 UH foi escolhido por ter sido validado microscopicamente para cortes finos (1-2 mm de espessura) de TCAR para a quantificação de enfisema (FELIX, 2007), mostrando ser capaz de realizar a segmentação automática do parênquima pulmonar e a extração da medida de área pulmonar, bem como calcular, de modo semiautomático, as variáveis relacionadas à gravidade do componente de enfisema pulmonar, DPM, AR e Perc15. Além disso, a solução classifica as regiões segmentadas correspondentes as áreas hiperaeradas, contrastando-as com áreas de pulmão normal.

Passado o panorama dos algoritmos de segmentação relacionados a este trabalho, finalmente, é importante destacar que os métodos considerados para a segmentação do pulmão serão os MCA's GVF, VFC, THR-mod, THR-multi, SISDEP e CRISP além dos métodos recentes CRAD e OPS. Estes algoritmos foram escolhidos, principalmente os quatro últimos, por apresentarem performance melhor que os tradicionais, incluindo em sua formulação procedimentos supervisionados, seja utilizando métodos de classificação ou heurísticas previamente definidas, o que remete à necessidade de estágios prévios de treinamento e conhecimento anterior do conjunto de dados. Os métodos até aqui abordados foram selecionados por serem dedicados à segmentação de imagens do pulmão, tornando a comparação com o FGAC mais precisa.

2.5 Detecção automática da curva de inicialização

Estudos anteriores mostram que o estágio de inicialização de métodos baseados em contornos ativos é uma etapa crítica no processo automático de segmentação. Rebouças Filho et al. (REBOUÇAS FILHO et al., 2013; REBOUÇAS FILHO, 2010) e Barros et al. (BARROS, 2016) indicam que abordagens fortemente influenciadas pelo fluxo do gradiente na imagem podem convergir precocemente se inicializados em regiões uniformes e distantes das bordas de interesse.

Em geral, a convergência precoce ocorre devido a maior influência da energia interna, uma vez que distante das bordas há uma baixa influência das energias externas

oriundas das bordas do objeto de interesse. Atuando apenas a energia interna, o resultado é que o contorno inicial reduzirá sua área até entrar em colapso em um único ponto, após sucessivas iterações (CAVALCANTE, 2010).

Afim de contornar estas limitações, surgiram abordagens que adicionam forças ao cálculo da energia a ser minimizada, para atrair a curva inicial até as regiões onde há influência do gradiente, como é o caso do MCA Balão de Cohen (COHEN, 1991) que adiciona o cálculo de um vetor oposto ao baricentro da curva de inicialização, afim de movê-la às regiões de interesse, discutido em mais detalhes na seção anterior.

Outras abordagens recentes, sugerem processos de inicialização automáticos baseados em descritores locais. O método de contorno ativo de Ilunga–Mbuyamba et al. (2017) aplicado na segmentação de tumores cerebrais, utiliza o descritor hierárquico HCSD (do inglês, *Hierarchical Centroid Shape Descriptor*) para detectar a região de inicialização. O descritor HCSD é baseado em sucessivas decomposições de uma imagem binária, cada decomposição produz um centroide. O HCSD produz um vetor com as coordenadas dos centroides de cada nível de decomposição. Na Figura 7 é ilustrada uma decomposição até o segundo nível em um recorte de um tumor cerebral em imagem binária.




Figura 7 – Decomposição HCSD, em (a) árvore de decomposição até o segundo nível; (b) recorte da componente binária sob análise.

No trabalho de Ilunga–Mbuyamba et al. (2017), as amostras S contendo as lesões são analisadas com uma janela w suficientemente pequena. A cada sobreposição de w em S , é calculado um descritor $HCSDw_i$, ao mesmo tempo uma distância euclidiana é calculada entre $HCSDw_i$ e as coordenadas de um $HCSD_{ref}$, este último representa a descrição previamente classificada de um tumor. A janela w_i que obtiver a menor distância é então atribuída como ponto de inicialização do contorno ativo. Entretanto, esta abordagem apresenta uma forte dependência do processo de binarização, além de impor a necessidade do conhecimento prévio do formato da lesão e ampliar o custo computacional para as diversas análises locais da janela w_i (ILUNGA–MBUYAMBA et al., 2017).

Já a abordagem proposta por He et al. (2017), utiliza um contorno ativo geodésico para segmentar o parênquima pulmonar em imagens intermediárias de uma sequência de cortes de TC. Os autores avaliam que o parênquima pulmonar apresenta-se em diferentes

formas, variando desde pequenas ou grandes regiões arredondadas até formatos elipsóides, dificultando a representação do contorno inicial sob uma forma geométrica pré-determinada.

Em seus estudos, He et al. (2017) analisaram um conjunto de 20 exames, com 200 cortes cada. Escolhem cortes conhecidos, chamados de pontos chave. Entre dois pontos chave, deseja-se identificar o contorno inicial para segmentar um corte intermediário. A partir do corte i , *pixels* são aleatoriamente selecionados formando um conjunto de componentes. Estes *pixels* são classificados pelo algoritmo não supervisionado *k-means*, identificando aqueles próximos à região pulmonar. A partir do conjunto de *pixels* classificados como pulmão, a região que representa a inicialização é identificada por interpolação, via método de Nystrom, com o conjunto de *pixels* do corte $i + 2$. A Figura 8 ilustra o procedimento proposto.




Figura 8 – Procedimento de inicialização proposto por He et al. (HE et al., 2017).

Por outro lado, Cid et al. (CID et al., 2015), propõem um procedimento simples de inicialização composto por três estágios. O primeiro estágio visa identificar estruturas do sistema respiratório. Executando, inicialmente, uma operação morfológica descrita por Soille (SOILLE, 2013) como preenchimento de buracos. Em que um buraco é definido como a região mais escura da imagem de TC, contornada por uma região mais clara.

Posteriormente, é feita uma diferença absoluta, *pixel a pixel*, entre a imagem original e o resultado do estágio anterior, apresentando uma área mais clara como resultado, representando a região aerada. O segundo estágio classifica os *pixels* em dois grupos, pulmão e não pulmão, utilizando o classificador *k-means*. Os *pixels* classificados como pulmão representam duas componentes que podem ser utilizadas como regiões de inicialização. O terceiro e último estágio aplica uma filtragem de ruídos, preservando apenas as duas componentes maiores.

Embora simples, a metodologia de Cid et al. (CID et al., 2015) assume que a região aerada possui um contraste bem definido em relação às bordas que estão além do pulmão, considerando apenas duas classes em seu estágio de classificação. Contudo, estudos apresentados por Rebouças Filho et al. (REBOUÇAS FILHO et al., 2017b), quanto a densidade dos tecidos humanos, indicam que há pelo menos 6 classes com densidades

UH distintas, além de patologias que aumentam a densidade UH como é o caso das amostras com fibrose. Indicando que esta abordagem pode não apresentar resultados satisfatórios para amostras com texturas heterogêneas. A Figura 9 apresenta uma síntese do procedimento de inicialização proposto em (CID et al., 2015).




Figura 9 – Procedimento de inicialização proposto por Cid et al. (CID et al., 2015).

Por outro lado, Barros et al. (BARROS, 2016) propõem uma inicialização baseada na classificação pixel a pixel utilizando classificador OPF (*optimum-path forest*), baseado em um grafo de menor custo. Afim de encontrar o caminho ótimo, a média dos pixels classificados como região de menor custo indica a posição de dois centroides, um para cada pulmão. O centroide é utilizado na construção de um polígono regular, que indica o contorno inicial da segmentação.

Na Figura 10(b) é possível observar o mapa de energia calculado pelo clasificador OPF, onde as regiões mais escuras representam as áreas de caminhos de menor custo, já as mais claras, representam picos de energia. A partir desta, dois centroides são calculados e um polígono simples é utilizado como contorno inicial da curva, Figura 10(c).




Figura 10 – Inicialização do OPS, (a) Exame de TC, (b) Energia externa e (c) centroides de inicialização.

De outro modo, estudos anteriores realizados por REBOUÇAS FILHO et al. (2013), concluíram que há quatro regiões comuns às imagens de TC do tórax. Destas, duas regiões, a Esquerda e a Direita, se destacam por constituir a região medial do imageamento, sendo a melhor localização contendo o parênquima pulmonar (Figura 11). Os autores sugerem descartar as regiões Superiores e Inferiores por representarem regiões aeradas, tornando-se semelhante ao interior do pulmão que também contém ar e que poderiam atuar confundindo o algoritmo de segmentação.

Rebouças Filho et al. concluem que utilizando apenas as regiões mediais, há um ganho nas taxas de acerto e na redução do tempo de processamento, já que uma menor




Figura 11 – Regiões utilizadas para encontrar os pontos para as inicializações da curva nos pulmões esquerdo e direito, nas posições, a) ápice; b) hilo; e c) base. Adaptado de (REBOUÇAS FILHO et al., 2013)

região será processada. A inicialização nos trabalhos de Rebouças Filho et al. (REBOUÇAS FILHO, 2010) é baseada na identificação de coordenadas x e y que representam o baricentro de um polígono regular de inicialização, em que as coordenadas são previamente classificadas por uma rede neural do tipo MLP.

As abordagens de Barros (2016) e REBOUÇAS FILHO (2010), REBOUÇAS FILHO et al. (2013), embora apresentem resultados promissores, requerem uma fase de treinamento prévio da rede neural MLP. Adicionando uma parcela de tempo necessária ao treinamento do modelo para a etapa de inicialização. Além disso, o contorno inicial é representado por um polígono regular, que, embora interno a região pulmonar, sugere um contorno inicial ainda distante das bordas do pulmão, requerendo assim um número maior de iterações para convergência da curva além de ser depende do número de vértices atribuídos à curva e não ao real contorno da região pulmonar.

2.6 Medidas de avaliação

Neste trabalho as métricas de avaliação foram baseadas na matriz de confusão, obtidas tomando como base as imagens marcadas por um especialista (GT, do inglês *Growth Through*) e as imagens resultantes de cada método de segmentação avaliado. O resultado da matriz de confusão forneceu os índices: Verdadeiro Positivo (TP), Verdadeiro Negativo (TN), Falso Positivo (FP) e Falso Negativo (FN).

Acurácia (Acc) é a relação entre as respostas do algoritmo e o conjunto das possibilidades de erros. Essa medida avalia os acertos do algoritmo em relação ao total de amostras apresentadas e indica, desta forma, a proximidade dos resultados obtidos daqueles desejados, sua fórmula é dada por:

$$Acc = \frac{TP + TN}{TP + FN + FP + TN} \quad (2.27)$$

A sensibilidade (Se) refere-se à capacidade do sistema de detectar corretamente as amostras que realmente pertencem a classe desejada. Neste trabalho, indica, portanto, a capacidade do método de identificar corretamente as regiões que verdadeiramente pertencem à região pulmonar. Esta medida é descrita como:

$$Se = \frac{VP}{VP + FN} \quad (2.28)$$

Outra métrica estatística é o Coeficiente de Correlação de Matthews (MCC). Discrimina o resultado do objeto a ser classificado e a saída produzida pelo algoritmo. O MCC é, em essência, um coeficiente que pode representar, assim como a Acc, uma taxa de acerto em uma matriz de confusão. Porém, diferentemente da Acc, esta métrica não apresenta viés quando há um desbalanceamento entre as classes. No contexto da segmentação, há um desbalanceamento natural ao problema, e este índice pode corroborar com os acertos calculados. Esta medida pode ser calculada da seguinte maneira:

$$MCC = \frac{(TP \times TN - FP \times FN)}{\sqrt{(TP + FP) \times (TP + FN) \times (TN + FP) \times (TN + FN)}}, \quad (2.29)$$

Hausdorff (1914) apresenta a distância Hausdorff (HD) no domínio de Hausdorff. Neste espaço, seus elementos também podem ser considerados conjuntos fechados e limitados, onde a distância euclidiana máxima entre eles é a chamada distância de Hausdorff. O HD pode ser calculado na seguinte equação:

$$HD = \max \{A, B\}, \quad (2.30a)$$

em que:

$$A = \sup_{x \in R_a} \inf_{y \in R_{gt}} d(x, y) \quad (2.30b)$$

$$B = \sup_{y \in R_{gt}} \inf_{x \in R_a} d(x, y), \quad (2.30c)$$

onde *sup* e *inf* representam o supremo e o ínfimo, respectivamente, e a função *d* retorna a distância entre *x*, que pertence ao resultado do algoritmo (R_a), e o ponto *y*, que pertence a segmentação de referência (R_{gt}) do especialista.

A distância de Hausdorff foi aplicada às imagens neste trabalho, e o resultado desta operação mostrou a distância máxima entre o contorno obtido pelo método de segmentação e o contorno do especialista. Neste caso, consideramos um bom índice aquele cujo resultado é a menor distância entre os pontos, sendo considerado, portanto, uma medida de similaridade.

Ainda na busca por similaridades entre os resultados, o coeficiente de Dice (DC) (DICE, 1945) é outra métrica importante para avaliar os métodos utilizados neste trabalho. Aqui, a segmentação proveniente do algoritmo e a segmentação do especialista são comparadas por sobreposição. O coeficiente DC é apresentado como:

$$Dice = 2 \cdot \frac{|S_a \cap S_{gt}|}{|S_a + S_{gt}|}, \quad (2.31)$$

onde S_a representa a segmentação do algoritmo e S_{gt} é a segmentação do especialista. Depois de sobrepor essas regiões, é possível extrair as taxas de ocorrência em que o valor 1 é a perfeita sobreposição. Portanto, quanto mais próximo este índice estiver de 1, mais próximo o resultado do algoritmo estará da segmentação desejada (QIAN et al., 2013).

Por fim, este trabalho também considerou o coeficiente de similaridade de Jaccard como uma medida estatística utilizada para comparar a similaridade e diversidade de conjuntos de amostras, esta medida é descrita em maiores detalhes no trabalho de Choi, Cha e Tappert (2010).

3 Metodologia

Uma das principais vantagens de modelos baseados em contornos ativos tradicionais é sua habilidade em tratar detecção de bordas como uma curva fechada. Isso representa uma evolução nos algoritmos de detecção de borda, uma vez que estes não costumam levar em conta a propriedade que uma região é fechada em si. Por exemplo, objetos com luminosidade localizada possuirão bordas com tonalidades diferentes, fazendo com que o objeto não seja identificado com exatidão (BERTUOL, 2007).

Entretanto, métodos baseado no MCA tradicional podem apresentar algumas limitações, dentre elas: **1)** O MCA tradicional pode ser considerado um modelo paramétrico. Este tipo de modelagem encontra dificuldades com o tratamento matemático dado a solução dos funcionais que definem o modelo, sendo necessário o desenvolvimento de esquemas computacionais eficientes para resolvê-lo (MARQUEZ-NEILA; BAUMELA; ALVAREZ, 2014; BERTUOL, 2007); **2)** Originalmente a curva paramétrica não trata mudanças topológicas, dificultando a detecção de regiões desconexas (BERTUOL, 2007). **3)** O algoritmo é fortemente dependente da região de inicialização e do campo de atração imposto pelo gradiente, o que dificulta sua utilização em imagens ruidosas e de baixo contraste (BARROS, 2016; REBOUÇAS FILHO et al., 2017c; REBOUÇAS FILHO et al., 2017b)

Assim, novas abordagens são propostas. Nas seções a seguir apresentamos um modelo geométrico de contorno ativo que serviu de fundamentação ao desenvolvimento da solução aqui proposta.

3.1 Uma abordagem morfológica para o contorno ativo geodésico

De acordo com Bresson et al. (2007), solucionar diretamente as EDPs utilizando métodos numéricos tradicionais, como a equação de Euler-Lagrange, pode ser até 60 vezes mais lento do que as aproximações do comportamento da curva utilizando técnicas de processamento de imagem.

Assim, buscando aproximações eficientes, estudos têm sido apresentando na literatura para reduzir o custo de tempo na solução destas equações. Neste sentido, soluções numéricas de equações diferenciais parciais foram propostas por Lax (1965). Seu trabalho foi pioneiro no uso de sucessivas dilatações e erosões morfológicas em múltipla escala (GONZALEZ, 2009), no intuito de oferecer um esquema numérico estável e eficiente para a resolução de EDPs.

A erosão e a dilatação fundamentam as operações da morfologia matemática. De

acordo com Soille (2013), estes operadores são baseados em teoria dos conjuntos e analisam a relação entre dois conjuntos conhecidos: o conjunto de pixels da imagem e um conjunto de pixels menores chamado elemento estruturante (EE). A dilatação com um elemento estruturante de raio h , pode ser definida como:

$$D_h[u(x)] = \sup_{y \in hB(0,1)} u(x+y) \quad (3.1)$$

onde x e y são coordenadas espaciais e B é um EE circular com raio 1, ponderado por um fator inteiro h . De maneira similar, a operação de erosão é representada por:

$$E_h[u(x)] = \inf_{y \in hB(0,1)} u(x+y) \quad (3.2)$$

Estas duas operações podem ser combinadas para produzir outros importantes operadores.

Seja $T_h[u(x)]$ um operador morfológico, é possível expressar a combinação da dilatação com erosão em um operador $\sup - \inf$, este operador define uma operação conhecida como abertura morfológica a qual atua removendo regiões menores que o elemento estruturante além separar componentes próximas, é descrita como:

$$T_h[u(x)] = \sup_{B \in B} \inf_{y \in x+hB} u(y) \quad (3.3)$$

por dualidade, é possível definir a operação de fechamento morfológico, útil para preencher descontinuidades e remover saliências na extremidade de uma componente binária e pode ser descrita como a operação $\inf - \sup$, tal que:

$$T_h[u(x)] = \inf_{B \in B} \sup_{y \in x+hB} u(y) \quad (3.4)$$

Neste sentido, Alvarez et al. (1993) demonstraram que uma relação de equivalência entre operadores diferenciais e morfológicos por meio de aplicações sucessivas de dilatação e erosão é possível, utilizando um elemento estruturante suficientemente pequeno. Com base neste estudo, podemos aproximar o comportamento da operação de dilatação morfológica, com uma equivalência infinitesimal, a solução da EDP $\frac{\partial u}{\partial t} = |\nabla u|$, sendo possível utilizando um h suficientemente pequeno, aqui representado pelo limite lateral à direita:

$$\lim_{h \rightarrow 0^+} \frac{D_h u - u}{h} = |\nabla u| \quad (3.5)$$

Novamente, por dualidade, a operação de erosão apresenta uma propriedade similar:

$$\lim_{h \rightarrow 0^+} \frac{E_h u - u}{h} = -|\nabla u| \quad (3.6)$$

com um comportamento equivalente a solução da EDP $\frac{\partial u}{\partial t} = -|\nabla u|$. Diferentemente do primeiro caso, aqui u apresenta uma variação negativa, indicando uma redução da área da curva em relação ao tempo.

Posteriormente, Catté, Dibos e Koepfler (1995) provaram que aplicações sucessivas de uma operação de média aritmética entre o resultado de dois operadores morfológicos, apresentam resultados equivalentes ao operador de curvatura apresentado pela EDP 2.24. Este operador é descrito pela equação:

$$F_h[u(x)] = \frac{SI_{2h}[u(x)] + IS_{2h}[u(x)]}{2} \approx \operatorname{div} \left(\frac{\nabla u}{|\nabla u|} \right) \cdot |\nabla u|, \quad (3.7)$$

onde F pode ser representado por $F_{\sqrt{h}}$, para um h suficientemente pequeno. E os operadores SI_{2h} e IS_{2h} , são os operadores $\sup - \inf$ e $\inf - \sup$, respectivamente.

Já Marquez-Neila, Baumela e Alvarez (2014) evoluem o operador de curvatura morfológico, proposto por Catté, Dibos e Koepfler (1995), adicionando a propriedade de invariança ao contraste. Eles propuseram então um operador de curvatura baseado na composição entre as operações $\sup - \inf$ e $\inf - \sup$:

$$(SI_{\sqrt{h}}) \circ (IS_{\sqrt{h}}) \approx \frac{T_h^2[u(x)] + T_h^1[u(x)]}{2} \quad (3.8)$$

onde T_h^1 e T_h^2 são dois operadores morfológicos assim como em Catté, Dibos e Koepfler (1995). Portanto, com um comportamento de equivalência infinitesimal, existe uma equivalência entre a composição de operadores morfológicos 3.8 e a EDP 2.24.

A Figura 12 apresenta aplicações sucessivas do operador de Marquez-Neila, Baumela e Alvarez (2014) em uma componente binária branca, representando aqui a deformação do Level Set zero. Ilustrando assim a contração do contorno (linha vermelha) ao passo que apresenta a equivalência com o operador de curvatura proposto anteriormente por Evans, Spruck et al. (1991).

Finalmente, inspirado nas equivalências entre operadores morfológicos e diferenciais, a EDP 2.26 pode ser resolvida por meio de aproximações por operadores morfológicos. Portanto, os operadores diferenciais podem ser substituídos pelas aproximações 3.5 e 3.6. Já a deformação do Level Set, pelo movimento imposto pelo operador diferencial de curvatura média, pode ser aproximado pelo operador de curvatura morfológica em 3.8.

Estas equivalências possibilitam o projeto de um contorno ativo geodésico morfológico com comportamento equivalente àquele baseado em EDPs, descrito anteriormente na Seção 2.3. Oferecendo, por outro lado, uma abordagem de implementação mais simples, com aproximações rápidas e sem problemas de estabilidade.




Figura 12 – Comparativo entre a aplicação do operador morfológico de Marquez-Neila, Baumela e Alvarez (2014), primeira linha, e o operador de curvatura definido sob a PDF de Evans, Spruck et al. (1991) na contração de uma componente binária branca, indicando a equivalência entre os operadores. Adaptado de Marquez-Neila, Baumela e Alvarez (2014).

3.2 Detector difuso de fronteira

Conforme descrito na seção 2.3.0.1, tradicionalmente o contorno ativo geodésico adiciona um detector de borda $g(I)$ que orienta a evolução da curva às bordas do objeto de interesse (CASELLES; KIMMEL; SAPIRO, 1997):

$$g(I) = \frac{1}{\sqrt{1 + \alpha |\nabla G_\sigma * I|}} \quad (3.9)$$

em que $G_\sigma * I$ é um filtro Gaussiano com desvio padrão σ e α é um fator de peso do gradiente.

No entanto, o detector de borda tradicional espalha a influência da energia, aqui representada pelo gradiente, para as regiões vizinhas próximos às bordas do objeto de interesse. Isso acontece devido a aplicação das derivadas gaussianas onde há um espalhamento proporcional ao parâmetro σ . Causando uma suavização do gradiente de maneira que as bordas dos objetos adjacentes se unam àquelas do objeto de interesse. Isto reduz a definição da borda e pode causar evoluções da curva além da fronteira desejada.

A Figura 13 apresenta duas patologias identificadas em decorrência do detector de borda tradicional aplicado próximo às regiões de borda do objeto de interesse. A primeira patologia, representada por 1, apresenta uma degradação da borda, tornando mais difícil identificar os limites da vizinhança entre duas regiões próximas. Já a segunda patologia identificada, representada por 2, é a degradação indesejada da região interna do objeto de interesse. Neste caso, a extremidade do pulmão esquerdo apresentou uma forte degradação após aplicação deste detector.

Por outro lado, inspirado nos experimentos de Sookpotharom (2009) para detecção de bordas em lesões de pele, neste trabalho é proposto um detector difuso de fronteira




Figura 13 – Energia externa calculada pelo detector de borda tradicional $g(I)$. (1) A patologia representa a degradação das bordas da região de interesse. (2) A patologia apresenta uma alta degradação da região interna devido a suavização de energia.

baseado na teoria de conjuntos *fuzzy* (TCF). A ideia principal é fuzzificar o cálculo do gradiente gaussiano da imagem, procurando identificar as regiões de borda, combinando este estágio com uma análise local dos gradientes. Uma função em conjunto *crisp*¹, pode expressar a relação das regiões por:

$$g_{crisp}(g(I)) = \begin{cases} x, & g(I) < \kappa \\ y, & g(I) \geq \kappa \wedge g(I) < \lambda \end{cases} \quad (3.10)$$

onde x é 0.10 e y é 0.34, estes valores foram obtidos baseados em testes sucessivos no conjunto de imagens de TC do tórax. Os parâmetros da função de fuzzificação são definidos por κ igual a 0.33 e λ com 0.50.

Os parâmetros κ e λ foram obtidos a partir de observações estatísticas em duas regiões do exame. A análise considera as regiões definidas pelas médias dos valores de gradiente encontrados na região externa e interna ao pulmão, ambas regiões são delimitadas próximas a fronteira da região de interesse.

A Figura 14, ilustra a dispersão dos gradientes em amostras de TC. Em uma análise geométrica, avaliando o raio como uma medida de dispersão, é possível perceber uma concentração da região interna do pulmão próxima ao centro, com raio inferior ou próximo a 0.33, já a média da região externa encontra-se mais próxima das extremidades, com raio superior a 0.33 e com máximos próximos a 0.50. Deste modo, é possível delimitar uma região interna próxima ao índice $\kappa = 0.33$, e uma segunda região externa delimitada pelo índice $\lambda = 0.50$.

¹ Conjunto *crisp* pode ser entendido como um conjunto rígido de pertinência, ou pertence (1) ou não pertence (0), lógica própria da álgebra booleana.




Figura 14 – Análise estatístico-geométrica do gradiente nas regiões internas a fronteira da cavidade pulmonar, na cor azul, e externas a fronteira na cor laranja. Aqui o gradiente representa o raio entre as regiões circulares definidas pelos índices Kappa e Lambda.

A partir destas observações, nota-se que não há uma clara definição de limites entre o que é pulmão e o que é borda. Neste sentido baseado na TCF é possível descrever estas regiões em variáveis linguísticas em função do gradiente: Pulmão, Região Não Desejada (RND) e Fronteira. A Figura 15 ilustra esta representação:




Figura 15 – Representação do gradiente gaussiano em variáveis linguísticas. Variáveis: Pulmão, Fronteira e Região Não Desejada (RND).

Neste ponto, ajustamos a função g_{crisp} , em notação de lógica nebulosa, descrevemos em uma função de fuzzificação:

$$g_{fuzzy}(g(I)) = \begin{cases} \text{Amplia intensidade,} & \text{é pulmão ou RND.} \\ \text{Reduz intensidade,} & \text{é fronteira.} \end{cases} \quad (3.11)$$

Como segundo passo, após a fuzzificação da função $g(I)$, para tratar as regiões nebulosas, uma análise local é realizada para expandir a diferença de energia entre as fronteiras adjacentes. Isto é possível buscando os valores mínimos locais do gradiente gaussiano resultante da função g_{fuzzy} . Aplica-se então uma erosão morfológica sobre o resultado, este procedimento é descrito pela equação:

$$\omega(x, y) = \min_{(u,v) \in H} \{g_{fuzzy}(x + u, y + v)\} \quad (3.12)$$

em que H é uma janela de dimensão 4 x 4 pixels, $x + u$ e $y + u$ são coordenadas de um ponto no gradiente gaussiano. Esta operação reduz a intensidade da energia dentro da região de influência definida por H . O resultado, portanto, é o realce das diferenças de gradiente entre as bordas e a região interna do tecido pulmonar, preservando o gradiente nas regiões do parênquima².

Como terceiro e último passo, uma análise similar é executada para unir regiões que podem ter sido degradadas pela manipulação do gradiente. Portanto, é aplicada uma segunda operação para corrigir as regiões internas do pulmão cuja energia foi realçada nas etapas anteriores. Tal correção é obtida buscando maximizar os valores locais do gradiente gaussiano, para tanto aplica-se uma dilatação morfológica, descrita pela Equação:

$$\Omega(x, y) = \max_{(u,v) \in H} \{\omega(x + u, y + v)\} \quad (3.13)$$

Este passo reduz as pequenas diferenças entre os gradientes locais, evitando assim que haja uma degradação excessiva das regiões internas onde há variações de intensidade. Neste ponto, vale lembrar que a função g_{fuzzy} é inversamente proporcional ao gradiente na imagem, o que justifica a utilização das funções de mínimo e de máximo na definição dos operadores ω e Ω .

O novo detector difuso de fronteira auxilia na evolução da curva por meio da correção do gradiente que será avaliado pela força balão. O método causa uma redução na influência do gradiente gaussiano nas regiões internas do parênquima pulmonar, reduzindo a influência das bordas de pequenas estruturas internas que, segundo REBOUÇAS FILHO et al. (2013), podem comprometer a evolução da curva. Além disso, preserva a definição das estruturas adjacentes. A Figura 16 ilustra o desempenho da solução proposta para os casos patológicos identificados anteriormente para o detector tradicional.

Um das vantagens desta abordagem é a sua robustez em relação as variações de contraste das amostras. Conforme REBOUÇAS FILHO et al. (2017b), imagens de TC do tórax costumam apresentar diferentes níveis de contraste, especialmente quando o pulmão apresenta patologias que influenciam a densidade dos tecidos. Patologias como DPOC diminuem a densidade em Unidades Hounsfield (UH), dando uma tonalidade mais

² O parênquima pulmonar representa a região interna da cavidade do pulmão, é formado por regiões aeradas e estruturas internas como vasos e vias respiratórias.

escura ao exame, já a Fibrose aumenta a densidade, deixando as amostras mais claras. Uma comparação do novo detector difuso de fronteira em relação ao detector de borda tradicional pode ser visualizada nas Figuras 17, 18 e 19 que apresentam amostras de pulmões saudáveis, além de casos com DPOC e fibrose, respectivamente.




Figura 16 – Energia externa calculada pelo novo detector difuso de fronteira. (1) Observa-se uma melhor separação entre as bordas da região de interesse e as estruturas adjacentes. (2) Não há degradação significativa da região interna do pulmão.

Por fim, propomos a substituição do detector de borda tradicional $g(I)$ pelo novo operador $\Omega(I)$. Assim, incorporando as equivalências das EDPs previamente discutidas, a evolução da curva para o FGAC pode ser definida rescrevendo a Equação 2.25 em termos de um Level Set:

$$\begin{aligned} \frac{\partial u}{\partial t} = \Omega(I)|\nabla u| \left(\operatorname{div} \left(\frac{\nabla u}{|\nabla u|} \right) + \nu \right) + \nabla \Omega(I) \nabla u \\ + \Omega(I) \cdot \nu \|\nabla u\|, \end{aligned} \quad (3.14)$$

onde I é uma imagem, neste caso, uma amostra de exame de TC, u é o Level Set, e ν é um limiar que define a atuação da força balão.

O FGAC, portanto, não depende da parametrização da curva e a minimização da energia deforma o Level Set, alterando a curvatura dos segmentos na curva, cuja evolução é guiada pela operação $\Omega(I)$. Finalmente a energia do FGAC é representada pelo funcional:

$$E(C) = \int_0^{\operatorname{length}(C)} \Omega(I)(C(s)) ds \quad (3.15)$$




Figura 17 – Comparativo entre a energia externa obtida pelo detector tradicional $g(I)$ e o novo detector difuso de fronteira $\Omega(I)$ aplicado em amostras de pulmões saudáveis.




Figura 18 – Comparativo entre a energia externa obtida pelo detector tradicional $g(I)$ e o novo detector difuso de fronteira $\Omega(I)$ aplicado em amostras de pulmões com DPOC.




Figura 19 – Comparativo entre a energia externa obtida pelo detector tradicional $g(I)$ e o novo detector difuso de fronteira $\Omega(I)$ aplicado em amostras de pulmões com Fibrose.

3.3 Detecção automática do Level Set inicial

Estudos anteriores mostram que o estágio de inicialização de métodos baseados em contornos ativos é uma etapa crítica no processo automático de segmentação. Rebouças Filho et al. (REBOUÇAS FILHO et al., 2013; REBOUÇAS FILHO, 2010) e Barros et al. (BARROS, 2016) indicam que abordagens fortemente influenciadas pelo fluxo do gradiente na imagem podem convergir precocemente se inicializados em regiões uniformes e distantes das bordas de interesse.

Em geral, a convergência precoce ocorre devido a maior influência da energia interna, uma vez que distante das bordas há uma baixa influência das energias externas oriundas das bordas do objeto de interesse. Atuando apenas a energia interna, o resultado é que o contorno inicial reduzirá sua área até entrar em colapso em um único ponto, após sucessivas iterações (CAVALCANTE, 2010).

De acordo com He et al. (HE et al., 2017), imagens de TC do tórax apresentam o pulmão como regiões que não possuem geometria bem definida. Dificultando a representação do pulmão como uma forma geométrica regular³. Neste sentido, uma estratégia mais adequada é identificar uma forma inicial mais próxima ao contorno da região pulmonar. Visando assim uma inicialização adaptativa, além de oferecer ao contorno ativo uma curva inicial muito próxima ao objeto de interesse.

Esta seção apresenta um algoritmo para detecção do contorno inicial próximo ao formato real da região pulmonar, com o objetivo de oferecer uma solução livre de estágios prévios de treinamento, reduzindo assim restrições de tempo para aplicações. Nesta abordagem, nós propomos um processo de inicialização completamente automatizado, baseado em reconstrução morfológica visando obter uma componente inicial semelhante ao formato real da região pulmonar.

3.3.1 Pré-Processamento

As imagens originalmente no formato DICOM foram normalizadas para uma matriz em escala de cinza, onde todos os pixels foram reduzidos a resolução de 8 bits, com intensidades na escala de cinza variando de 0 a 255. De acordo com os estudos apresentados por Rebouças Filho et al. (REBOUÇAS FILHO et al., 2017b), observa-se que a região pulmonar possui diferentes estruturas tais como vias respiratórias, tecido ósseo e regiões não aeradas. Estas estruturas apresentam diferentes densidades UH e influenciam sua representação em imagens normalizadas para tons de cinza.

³ Um polígono diz-se regular se tiver todos os seus lados e ângulos iguais, sejam eles internos ou externos.

3.3.2 Deslocamento de Contraste

Originalmente aplicado em imagens médicas por Pizer et al. (PIZER et al., 1987), a equalização adaptada de histograma com limitação de contraste - CLAHE (do inglês, *Contrast Limited Adaptive Histogram Equalization*), é uma variante da equalização de histograma, e tem sido aplicado recentemente em diferentes aplicações de realce de imagens (KIM; JEON; EOM, 2016; LAKSMI et al., 2016). Este algoritmo, analisa a imagem em pequenos blocos, como regiões contextuais, e aplica uma equalização em cada região. O algoritmo possui um parâmetro conhecido como *Clip limit*, que limita o número de pixels que podem atingir um certo nível de cinza dentro do histograma. A fatia do histograma que é "cortada", então é distribuída igualmente entre as demais escalas.




Figura 20 – Representação do corte de contraste no histograma, M corresponde a média global e DC é o parâmetros de deslocamento aplicado.

Inspirado no parâmetro de *Clip limit* do CLAHE, propomos um ajuste de contraste baseado no deslocamento das faixas do histograma. Após o cálculo da média M dos pixels da amostra de TC do tórax, todos os pixels que estiverem a uma faixa de distância DC (Deslocamento de Contraste) de M , terão suas intensidades reduzidas proporcionalmente. O resultado esperado com esta operação é deslocar as intensidades das regiões predominantemente escuras para a esquerda do histograma, ou seja, tornar as regiões escuras ainda mais escuras, sem afetar as demais regiões predominantemente claras, este procedimento é ilustrado na Figura 20.

Seja I uma imagem, M o valor médio das intensidade em I e CP um valor inteiro que rege o deslocamento do contrate, este procedimento pode ser descrito pela Equação:

$$I(x, y) = \begin{cases} I(x, y) - DC, & I(x, y) < M \\ I(x, y), & \text{senão.} \end{cases} \quad (3.16)$$

A Figura 21 ilustra diferentes aplicações com ajuste do parâmetro DC em imagens de TC do tórax. Os experimentos mostram que quanto maior o valor de DC , maior será o deslocamento das intensidades, reduzindo a intensidade das regiões aeradas do exame. O resultado obtido foi a ampliação do contraste na região pulmonar.




Figura 21 – Histograma das aplicações do Deslocamento de Contraste com diferentes parâmetros DC em um exame de TC do tórax.

Após a leitura e normalização da imagem de TC do tórax, foi aplicada um deslocamento de contraste onde o valor DC escolhido foi baseado em testes com 72 imagens de pulmão, o parâmetro que apresentou melhores resultados foi aproximar DC do valor da média das intensidades (Figura 22.2).

3.3.3 Detecção das componentes de inicialização

Após o realce da região pulmonar, aplicou-se uma operação de binarização usando o limiar de Otsu (OTSU, 1975), seguida de uma filtragem morfológica (erosão⁴ seguida de uma dilatação⁵) para filtragem de pequenas componentes ruidosas. Estas operações são descritas em (GONZALEZ, 2009). Os resultados destas etapas podem ser observados nas Figuras 22.3 e 22.4.

O passo seguinte calcula a área das componentes conexas da imagem binária. A componente que apresenta a maior área é então preservada (Figura 22.5). Após a binarização, é importante observar que existem amostras em que as bordas dos dois pulmões estão muito próximas. Esta característica afeta o resultado da binarização, em que são esperadas duas regiões escuras disjuntas, mas apenas uma é identificada, unindo indevidamente os dois pulmões. Cabe, neste ponto, um procedimento de correção estrutural.




Figura 22 – Procedimento proposto para identificação do level set de inicialização.

A etapa de análise estrutural inicia com uma amostragem vertical da imagem invertida (Figura 22.6). Uma varredura nas colunas é realizada, e a cada coluna analisada, uma distância euclidiana média dos pixels brancos é calculada em relação ao *background* escuro. O resultado dessa amostragem é um vetor $D = \{d_1, d_2, d_3, \dots, d_i, d_{i+1}, d_n\}$, em que

⁴ Elemento estruturante retangular de 3 x 4 pixels.

⁵ Elemento estruturante retangular de 5 x 2 pixels.

cada elemento representa a distância média dos pixels brancos da amostra e n é um fator de amostragem definido como:

$$n = \log_2 W + 1, \quad (3.17)$$

em que W é a largura da imagem.

A zona de junção dos pulmões (Figura 23.2) é então detectada da seguinte forma. Considere um valor inteiro H que atua como limiar e S_i , $0 < i < n$, representando a n -ésima amostra vertical. Todos os *pixels* $p = [x, y]$ que pertencem a S_i cuja distância média d_i é menor que H , são desativados, isto é, mudam sua intensidade para zero na imagem binária u . Do contrário, a intensidade do pixel é preservada. Esta operação é descrita na Equação 3.18.

$$u(p) = \begin{cases} 0, & d_i < H \wedge p \in S_i \\ 1, & \text{senão} \end{cases} \quad (3.18)$$

Como os pixels que formam a zona de junção tendem a ter a menor altura, logo terão a menor distância média. Neste trabalho atribuímos o valor de H como sendo a menor média⁶ que indique a menor dispersão possível do conjunto D . Optou-se, desde modo, por utilizar a média harmônica dos valores $d_i \in D$. A Figura 23 ilustra a operação de correção estrutural para separar a zona de junção.

Neste estágio, já é possível observar as componentes binárias próximas a região pulmonar, Figura 22. Podem existir, entretanto, artefatos na imagem que atuam como ruído e precisam ser removidos, como é o caso das regiões aeradas superiores e inferiores, ilustradas anteriormente na Figura 11. Neste sentido, separamos apenas as componentes desejadas por meio de um processo de reconstrução, descrito na seção a seguir.




Figura 23 – Análise estrutural para separação das componentes pulmonares. A distância média d é calculada para cada amostra, aquelas com distância inferior ao limiar K são identificadas para correção.

⁶ Segundo Pereira et al. (2014), sejam as médias: A - Aritmética, G-Geométrica e H-Harmônica, estas medidas obedecem a propriedade $H < G < A$, dado um conjunto de valores onde ao menos dois elementos são distintos.

3.3.4 Reconstrução Morfológica

A reconstrução morfológica, descrita em (GONZALEZ, 2009; SOILLE, 2013), é baseada em sucessivas dilatações geodésicas e envolvem duas imagens, uma chamada de marcador e outra de máscara. A imagem resultante da seção anterior é utilizada como máscara (g). Já o marcador (m) é um corte na imagem binária, inspirado na região medial do exame, mais especificamente nas regiões esquerda e direita, definidas no trabalho de REBOUÇAS FILHO et al. (2017b).

Neste sentido, são aplicadas sucessivas dilatações geodésicas ao marcador m com um elemento estruturante h^7 , o resultado de cada dilatação é combinado com a máscara g . Esta combinação é descrita como uma operação de interseção entre as imagens, necessária para reger o crescimento do marcador em relação a máscara. A dilatação geodésica é descrita por Gonzalez et al. (GONZALEZ, 2009) como:

$$D_g^{(1)}(m) = (m \oplus h) \cap g. \quad (3.19)$$

Finalmente, baseada na aplicação sucessiva de dilatações geodésicas, a reconstrução morfológica é definida. Aqui o marcador m sofre deformações evoluindo em relação a máscara g até a convergência onde não há mais aumento de área. De acordo com Gonzalez et al. (GONZALEZ, 2009), esta operação pode ser definida pela equação:

$$D_g^{(k)}(m) = D_g^{(k)}(m) \left[D_g^{(k-1)}(m) \right], \quad (3.20)$$

onde k^8 representa um limite ao número de iterações. A Figura 24 ilustra o processo de reconstrução morfológica até aqui descrito.




Figura 24 – Reconstrução morfológica para detecção do Level Set inicial.

Tradicionalmente, o Level Set zero é definido como uma função de distância ou de probabilidade que define se uma determinada região pertence ou não à área do Level Set. Contudo, esta definição não leva em consideração características da estrutura do objeto de interesse tais como o formato aproximado da região desejada (MARQUEZ-NEILA; BAUMELA; ALVAREZ, 2014; CASELLES; KIMMEL; SAPIRO, 1997). Neste aspecto,

⁷ O elemento estruturante h é definido como um quadrado de 3 x 3 pixels.

⁸ Após experimentos em 72 pulmões, o valor de k foi fixado em 200.

nossa abordagem representa o Level Set zero como duas componentes binárias, cujas forma e área se aproximam daquelas observadas nos contornos da região pulmonar.

Esta estratégia oferece ao contorno ativo uma inicialização em estágios avançados de evolução, contribuindo para a redução do número de iterações ainda necessárias para a convergência do método. Isso dá ao contorno ativo um forte potencial para a redução do tempo de convergência além de oferecer ao método uma robustez maior às diferenças de topologia que ocorrem internamente ao parênquima pulmonar, reduzindo o espaço de análise dentro do processo de evolução da curva além de atenuar a influência de regiões patológicas.

Nas Figuras 25, 26 e 27 ilustramos diferentes inicializações (em amarelo) e o número de iterações necessárias para a convergência em pulmões saudáveis, com DPOC e fibrose, respectivamente, em comparação com a inicialização proposta (em azul). Na última coluna, o contorno de convergência (em vermelho). A inicialização I e II representam inicializações manuais próximas à região do pulmão e requerem mais iterações para convergir. A inicialização automática proposta, em azul, requer poucas iterações e alcança rapidamente a convergência de segmentação.




Figura 25 – Exemplos de inicialização utilizadas pelo FGAC em pulmões saudáveis.




Figura 26 – Exemplos de inicialização utilizadas no FGAC em pulmões com DPOC.

Por fim, a Figura 28 ilustra o processo de evolução da curva, embutida no Level Set identificado automaticamente pela solução proposta. O Level Set evolui com a aplicação do operador de curvatura, sendo atraído pela força balão em direção às bordas identificadas pelo detector difuso de fronteira.




Figura 27 – Exemplos de inicialização utilizadas pelo FGAC em pulmões com fibrose.




Figura 28 – Diagrama do FGAC com a evolução do contorno em uma amostra de TC do tórax, segmentando a região pulmonar.

3.4 Aquisição das Imagens Médicas

O banco de imagens utilizado neste trabalho constitui um conjunto de imagens obtidas em parceria com o Hospital Walter Cantídio da Universidade Federal do Ceará. Cedidas por estudos anteriores (FORTALEZA, 2006), sob aprovação do Comitê de Ética em Pesquisa da UFC – Protocolo nº 35/06, atendendo às exigências da resolução nº 196/96 do Conselho Nacional de Saúde, a respeito de pesquisas em seres humanos (Anexo A).

Os exames foram coletados a partir dos equipamentos Toshiba Aquilion (TA), GE Medical System LightSpeed16 (GEMSL) e Philips Brilliance 10 (PB). Todas as imagens foram coletadas originalmente no formato DICOM⁹, sob uma resolução de 16 bits por *pixel*, dimensão de 512×512 *pixels*, obtidas nas condições da janela pulmonar de -600 e 1600 UH, para o centro e largura, respectivamente. Todas as imagens foram adquiridas nas posições de ápice, hilo e base no plano de corte axial. Estas perspectivas de imageamento são ilustradas na Figura 29.

A base de imagens totaliza um conjunto de 36 exames de TC, contendo dois pulmões cada, consolidando um total de 72 pulmões para análise. As imagens estão distribuídas igualmente entre pacientes saudáveis, com DPOC e fibrose. A distribuição dos pulmões por categoria é: 27 pulmões saudáveis, 21 com fibrose e 24 com DPOC.




Figura 29 – Diferentes tipos de corte em TC. (a) ápice; (b) hilo; (c) base.

⁹ DICOM é uma abreviação de *Digital Imaging and Communications in Medicine*

4 Resultados

Neste capítulo, discutiremos a metodologia de avaliação proposta, avaliada sob a ótica das medidas descritas na seção 2.6, além do tempo necessário para a convergência do método. Ao final, uma discussão considerando a abordagem proposta frente aos algoritmos de segmentação pulmonar já consolidados na literatura será realizada.

4.1 Metodologia de avaliação

Neste trabalho, consideramos a metodologia de avaliação sob três perspectivas: índices quantitativo e de similaridade além do tempo de convergência. As medidas Se, Acc e MCC formam os índices quantitativos, avaliam a interseção entre o resultado e a marcação do especialista - *ground-truth* (GT). Já os índices de similaridade HD, DICE e Jaccard indicam o quão próximo está a morfologia da segmentação do algoritmo em relação a região de interesse definida pelo GT.

Além do índice quantitativo e de similaridade, o tempo de segmentação também foi avaliado como uma medida do desempenho da nova abordagem em relação aos outros métodos de segmentação pulmonar. Os testes foram realizados usando um processador Intel Core i5, 3.40GHz com 4GB de RAM e o código fonte foi escrito na linguagem Python 3. Testes de segmentação foram realizados em 72 imagens pulmonares distribuídas igualmente entre amostras de fibrose, DPOC e saudáveis, como descrito na seção 3.4.

A Figura 30 ilustra o cenário de avaliação proposto neste trabalho. Nas seções seguintes serão abordadas cada uma das etapas, iniciando pela análise quanto ao tempo de segmentação e na sequência a análise de quantitativa e de similaridade.




Figura 30 – Mapa mental que ilustra a metodologia de avaliação proposta. No canto superior à esquerda, o banco de exames de TC. No centro, as métricas de avaliação. À direita, os métodos de segmentação avaliados frente a abordagem proposta.

4.2 Análise dos resultados

Inicialmente, considerando os testes de tempo, o melhor tempo médio de segmentação foi obtido pelo método proposto, alcançando $1,98 \pm 0,50$ segundos para convergir a segmentação dos pulmões esquerdo e direito simultaneamente. Esta marca supera os métodos CRAD, SISDEP e OPS-Euclidiano com $2,00 \pm 0,16$, $4,90 \pm 2,02$ e $5,86 \pm 1,96$, respectivamente. Já o método GVF apresentou a segmentação mais lenta com 240 segundos, em média.

A abordagem morfológica com inicialização próxima às bordas do pulmão mostrou-se capaz de acelerar o processo de segmentação. O Level Set identificado no estágio de inicialização representa uma curva em estágio de evolução avançado, i.e., o Level set já inicia com formato bastante aproximado da região de interesse. Além de evitar os ruídos presentes internamente ao pulmão, essa proximidade reduziu o número de iterações ainda necessárias a convergência da segmentação.

Assim, o resultado de tempo obtido pelo método proposto demonstra o seu potencial competitivo, especialmente em sistemas de diagnóstico, em que o tempo de identificação do pulmão é um fator de restrição. Essa abordagem também pode ser usada como estágio de segmentação na classificação de doenças, reduzindo a análise de um exame completo de tomografia computadorizada para uma região de interesse pulmonar, acelerando assim o tempo de resposta. Um comparativo do tempo médio de segmentação está disponível na Tabela 1.

Tabela 1 – Comparação dos tempos médios de segmentação do FGAC em relação aos demais métodos.

Métodos	Tempo médio(s)
GVF	240.00±3.05
VFC	030.00±2.67
OPS	008.27±2.63
OPS Euclidean	005.86±1.96
SISDEP	004.90±2.02
CRAD	002.00±0.16
FGAC	001.85±0.50

De acordo com as Equações 3.9 e 3.14, o contorno ativo geodésico requer os parâmetros σ para as derivadas gaussianas, ν para a força balão e α como um fator de peso para o gradiente. Em nossos experimentos, o α teve uma baixa influência nos resultados e foi fixado em 1500, por outro lado, σ e ν influenciaram a evolução do contorno principalmente em regiões com altas variações de contraste, comprometendo também o tempo de segmentação.

Assim, avaliamos os dois parâmetros de acordo com os índices quantitativos e de similaridade. A Tabela 2 mostra as diferentes combinações. Por outro lado, de acordo com os índices, os melhores valores encontrados para σ foram entre 4 e 10 e para ν estavam entre 0,35 e 0,60.

Tabela 2 – Melhores configurações das derivadas gaussianas (σ) combinadas com o limiar da Força balão (ν). As diferentes combinações foram avaliadas sob a perspectiva das métricas de similaridade e quantitativas, além do tempo de convergência.

σ	ν	ACC	MCC	Se	HD	DICE	Jac	Time (s)
4.0	0.35	97.77	92.62	97.62	6.43	93.49	88.82	3.51
4.0	0.40	98.92	95.82	97.08	5.44	96.46	93.18	2.18
4.0	0.45	98.9	95.67	96.7	5.53	96.31	92.93	2.05
4.0	0.50	98.86	95.54	99.21	5.57	96.19	92.73	1.85
4.0	0.55	98.83	95.35	95.85	5.72	96.0	92.39	1.9
4.0	0.60	98.81	95.22	95.47	5.82	95.89	92.18	1.83
6.0	0.35	96.4	88.61	95.84	7.61	89.8	83.27	4.86
6.0	0.40	98.28	93.99	95.28	6.05	94.85	90.66	2.7
6.0	0.45	98.43	93.99	95.1	5.92	94.76	90.64	2.58
6.0	0.50	98.68	94.7	94.92	5.84	95.4	91.57	2.3
6.0	0.55	98.8	95.21	94.41	5.73	95.89	92.18	1.85
6.0	0.60	98.77	95.06	94.05	5.81	95.74	91.92	1.83
8.0	0.35	92.66	78.7	95.22	9.85	80.46	70.09	7.74
8.0	0.40	97.39	90.86	94.6	6.98	91.96	86.16	3.83
8.0	0.45	98.13	92.96	94.35	6.34	93.8	89.04	2.76
8.0	0.50	98.46	93.88	94.19	6.14	94.69	90.26	2.4
8.0	0.55	98.47	93.92	94.09	6.11	94.72	90.32	2.39
8.0	0.60	98.62	94.44	93.45	6.02	95.23	90.97	2.08
10.0	0.35	88.9	72.75	96.27	11.34	74.93	63.16	9.18
10.0	0.40	94.99	84.23	95.7	9.08	85.94	76.96	6.53
10.0	0.45	97.68	91.58	95.2	6.95	92.55	87.03	3.16
10.0	0.50	98.18	93.09	94.99	6.49	93.95	89.16	2.54
10.0	0.55	98.34	93.49	94.9	6.36	94.36	89.66	2.54
10.0	0.60	98.49	94.01	94.23	6.33	94.89	90.34	2.12

Mais adiante, a Figura 31 mostra as combinações dos diferentes parâmetros e o resultado de acordo com os índices quantitativos e de similaridade. Os melhores resultados foram alcançados pela combinação de 4,0 e 0,50 para σ e ν , respectivamente. Portanto, a melhor combinação de parâmetros identificam a solução com as melhores medidas de desempenho em comparação com a segmentação manual do especialista.

As configurações que obtiveram os melhores resultados foram submetidas a avaliação quantitativa de acordo com as medidas Se, Acc e MCC, como pode ser visto na Figura 31, além destes, consideramos o grau de proximidade entre a região segmentada pelo método e o GT, segundo as medidas HD, DICE e Jaccard, como índices de similaridade.




Figura 31 – Resultado dos índices quantitativos e de similaridade para os parâmetros da gaussiana do FGAC (σ) e força de balão (ν) aplicados ao conjunto de amostras de TC do tórax. Considerando esta análise, os melhores resultados foram obtidos com os parâmetros $\sigma = 4.0$ e $\nu = 0.50$.

Assim, de acordo com os índices quantitativos, o FGAC obteve os melhores resultados quando comparado aos métodos não supervisionados, superando os demais em mais de um por cento nas medidas Se, Acc, MCC. A proporção de previsões corretas, ACC, alcançou um resultado de $98,86 \pm 00,46$ superando todos os métodos não supervisionados, Tabela 3 e o método supervisionado CRISP com $98,04 \pm 00,89$, Tabela 4.

Tabela 3 – Índices quantitativos para o FGAC frente aos métodos de segmentação não supervisionados.

ACM	Índices quantitativos		
	Se	Acc	MCC
FGAC	99.21±00.66	98.86±00.46	95.54±01.92
VFC	98.26±01.31	97.88±01.29	92.13±03.20
GVF	96.75±05.10	96.79±03.61	90.00±06.45
THR mod	98.22±01.28	97.56±01.63	91.34±03.09
THR multi	97.68±03.45	95.77±03.96	85.38±11.85

Tabela 4 – Índices quantitativos para FGAC contra métodos de segmentação supervisionados.

ACM	Índices quantitativos		
	Se	Acc	MCC
FGAC	99.21±0.66	98.86±0.46	95.54±1.92
OPS-Euclidiano	99.00±0.79	98.93±0.53	96.14±1.29
SISDEP	98.99±0.65	98.89±0.52	95.87±1.13
CRISP	98.01±1.23	98.04±0.89	92.67±2.73
CRAD	99.45±0.43	98.99±0.57	96.13±1.86

Os métodos GVF e o VFC foram afetados negativamente pela influência do fluxo oposto do gradiente, proveniente das bordas próximas a concavidades, este comportamento pode ser visto na Figura 32. De forma semelhante, os métodos baseados na transformada THR foram afetados pelas variações de gradiente internas ao pulmão, provenientes das estruturas pulmonares, especialmente nas amostras com a patologia fibrose que altera a densidade UH do tecido, tornando as estruturas mais claras, influenciando assim o gradiente interno. Apresentando, portanto, uma convergência precoce da curva.

Por outro lado, o FGAC suaviza a influência do gradiente nas regiões internas, preservando a região de interesse do tecido, o detector de borda *fuzzy* identifica com maior precisão as fronteiras do pulmão, e combinado com a força balão evolui de forma satisfatória, superando as limitação daqueles métodos.

O FGAC supera os problemas induzidos pelas regiões internas por meio de sua inicialização automática, com um Level Set binário muito próximo das bordas do pulmão. Esta característica evita que a evolução da curva seja afetada pelo gradiente das estruturas tais como vias respiratórias, tecido ósseo e regiões não aeradas.

De acordo com o desvio padrão, que pode indicar a estabilidade do método, o FGAC alcançou índices de ACC equivalentes ou superiores ao OPS-Euclidiano, SISDEP e CRAD




Figura 32 – Comparação entre FGAC e métodos de segmentação não supervisionados. A primeira linha mostra resultados em uma amostra com DPOC, na segunda e terceira pulmão saudáveis e com fibrose, respectivamente.

com $98,93 \pm 00,53$, $98,89 \pm 00,52$ e $98,99 \pm 00,57$, respectivamente. A nova abordagem, por outro lado, alcançou $99,21 \pm 00,66$ para a medida Se, mostrando-se superior aos métodos VFC, GVF, RHT mod e RHT multi e os supervisionados OPS-Euclidiano, SISDEP e CRISP, indicando sua capacidade em identificar corretamente as regiões que realmente pertencem a região pulmonar. Da mesma forma, o FGAC alcançou $95,54 \pm 00,46$ para o índice MCC, superando todos os métodos não supervisionados. Esses resultados indicam o potencial do método para segmentar regiões pulmonares reais diferenciando-as das regiões não relevantes. Uma comparação visual pode ser observada na Figura 35.

Tabela 5 – Índices de similaridade para FGAC em comparação com os métodos de segmentação não supervisionados.

Método	Índices de similaridade		
	HD	DICE	Jaccard
FGAC	5.57 ± 01.17	96.19 ± 01.93	92.73 ± 03.43
VFC	6.92 ± 01.50	93.33 ± 02.82	87.62 ± 04.81
GVF	7.55 ± 02.29	91.76 ± 04.84	85.11 ± 07.71
THR mod	6.93 ± 01.79	92.81 ± 02.21	86.65 ± 03.79
THR multi	8.23 ± 02.91	87.29 ± 11.18	78.82 ± 14.43

Para os índices de similaridade, quando comparados aos resultados não supervisionados, conforme Tabela 5, o FGAC atingiu $5,57 \pm 1,17$, $96,19 \pm 1,93$, $92,73 \pm 3,43$ para o índices HD, DICE e Jaccard, respectivamente. Estes resultados são superiores àqueles obtidos pelos métodos não supervisionados. O desempenho do método mostra que além

Tabela 6 – Índices de similaridade para o FGAC em relação aos métodos de segmentação supervisionados.

Método	Índices de similaridade		
	HD	DICE	Jaccard
FGAC	5.57±1.17	96.19±1.93	92.73±3.43
OPS-Euclidiano	5.29±1.14	96.76±1.12	93.75±2.09
SISDEP	5.46±1.15	96.52±1.01	93.30±1.87
CRISP	6.33±1.32	93.73±2.70	88.31±4.56
CRAD	5.14±1.17	96.73±1.73	93.72±3.15

de conseguir uma convergência rápida, é capaz de segmentar a região do pulmão enquanto preserva a forma correta da região de interesse. Superando problemas de topologia e concavidade, comuns aos métodos VFC, GVF e CRISP. A Tabela 5 fornece os resultados para a FGAC em relação aos métodos de segmentação não supervisionados. Uma comparação visual pode ser observada na Figura 36.

Os resultados mostram que é possível segmentar regiões que muitas vezes representam problemas, como regiões de baixo contraste (Figura 33.a), côncavas (Figura 33.b) e com ruídos provenientes de patologias (Figura 33.c). Essas figuras representam imagens em que outros métodos frequentemente falham.




Figura 33 – Segmentação de amostras onde frequentemente outros métodos falham.

Além disso, quando comparado aos métodos supervisionados, mostrados na Tabela 6, o FGAC também apresenta excelentes resultados e supera o método CRISP em todas as métricas de avaliação. Além disso, o método proposto também alcançou resultados equivalentes aos métodos OPS-Euclidiano, SISDEP e CRAD. Na medida HD, por exemplo, os resultados mostram que a diferença entre CRAD e FGAC é de apenas 0,43. Já o CRAD alcançou o menor valor HD com desvio padrão de 1,17. Considerando o desvio padrão, portanto, pode-se concluir a equivalência ao resultado apresentado pelo FGAC.

A equivalência entre o método proposto e as outras abordagens supervisionadas pode ser observada nos resultados da Figura 34. Ressalta-se que o FGAC não necessita de estágios de treinamento prévio com classificadores ou indicação manual das regiões pulmonares, reduzindo assim o tempo de calibração do método, além disso, a FGAC não depende da parametrização de classes, como acontece com os métodos OPS, CRISP e




Figura 34 – Comparação entre FGAC e métodos de segmentação supervisionados. As linhas apresentam amostras com DPOC, saudáveis e com fibrose, respectivamente.

CRAD. Oferecendo uma técnica de segmentação rápida, simples e igualmente robusta.




Figura 35 – Gráfico de barras com linha de tendência comparativa entre FGAC e os métodos Tradicionais e Supervisionados, sob uma análise quantitativa.




Figura 36 – Gráfico de barras com linha de tendência comparativa entre FGAC e os métodos Tradicionais e Supervisionados, sob uma análise de similaridade.

5 Conclusão

O FGAC apresentou robustez quanto aos problemas de concavidade e convergência precoce, discutidos no capítulo 2 deste trabalho, limitações presentes no MCA tradicional e nos MCAs GVF, VFC, THR mod e multi, como observado nas comparações das Figuras 32 e 34. A proposta do detector difuso de fronteira apresentou relevância ao evitar a degradação da região interna do pulmão além de favorecer a definição das bordas dos pulmões quando suas fronteiras estão próximas. Evitando assim a união indesejada das componentes durante a segmentação.

A metodologia de avaliação proposta mostrou que o método de segmentação FGAC alcançou excelentes resultados para os índices quantitativos, superando todos os métodos tradicionais que não utilizam nenhum conhecimento a priori quanto a base de imagens ou estágios de treinamento supervisionado, alcançando valores relevantes para sensibilidade ($99.21 \pm 0.66\%$), acurácia ($98.86 \pm 0.46\%$) e MCC ($95.54 \pm 1.92\%$). O FGAC também supera o método CRISP em todas as medidas.

Quanto aos índices de similaridade, os resultados indicam que o FGAC preservou a morfologia da região de interesse quando comparada ao padrão ouro definido pelo especialista. Mostrou-se novamente superior a todos os MCAs não supervisionados, além de apresentar resultados superiores ao MCA CRISP e equivalentes ao OPS Euclidiano, SISDEP e CRAD, com HD (5.57 ± 1.17), DICE ($96.19 \pm 1.93\%$) e Jaccard ($92.73 \pm 3.43\%$). Indicando assim seu potencial competitivo frente aos métodos já consolidados na literatura sem utilizar treinamentos prévios, como é necessário aos métodos supervisionados, ou da identificação de classes como no MCA CRISP e SISDEP.

A inicialização automática do FGAC além de encontrar um Level Set suficientemente próximo a região de interesse, evitou o processamento de regiões internas do parênquima pulmonar. O tempo médio de segmentação, portanto, foi menor do que outros métodos de contorno ativos. Indicando que FGAC possui potencial competitivo em relação às demais técnicas, sugerindo sua aplicabilidade como método rápido e estável para segmentação da região pulmonar em imagens de TC do tórax, especialmente para aplicações com restrições de tempo.

Os próximos passos deste estudo visam analisar o desempenho do método proposto em uma base de imagens com outras doenças pulmonares, a fim de avaliar a robustez do método. Além disso, visamos avaliar o uso do FGAC como estágio de segmentação do pulmão para classificação de malignância em nódulos pulmonares, e depois, avaliar a aplicabilidade do método em situações com restrições de tempo e sua adequação para sistemas de apoio diagnóstico em tempo real.

6 Anexo A



Universidade Federal do Ceará
Comitê de Ética em Pesquisa

Of. Nº 107/06

Fortaleza, 31 de março de 2006

Protocolo COMEPE nº 36/06

Pesquisador responsável: Simone Castelo Branco Fortaleza

Deptº./Serviço: Hospital Universitário Walter Cantídio

Título do Projeto: "Efeitos da administração da CPAP sobre o parênquima pulmonar nas posições prona e supina em pacientes com doença pulmonar obstrutiva crônica: alterações na tomografia computadorizada de alta resolução e correlação com a dispnéia"

Levamos ao conhecimento de V.Sª. que o Comitê de Ética em Pesquisa da Universidade Federal do Ceará – COMEPE, dentro das normas que regulamentam a pesquisa em seres humanos, do Conselho Nacional de Saúde – Ministério da Saúde, Resolução nº196 de 10 de outubro de 1996 e complementares, aprovou o projeto supracitado na reunião do dia 30 de março de 2006.

Outrossim, informamos, que o pesquisador deverá se comprometer a enviar o relatório parcial e final do referido projeto.

Atenciosamente,

Dr. Fernando A. Freire Bezerra
Coordenador do Comitê
de Ética em Pesquisa
COMEPE/UFC

Referências

- ALEXANDRIA, A. R. D. et al. psnakes: A new radial active contour model and its application in the segmentation of the left ventricle from echocardiographic images. *Computer methods and programs in biomedicine*, Elsevier, v. 116, n. 3, p. 260–273, 2014. Citado na página 37.
- ALVAREZ, L. et al. Axioms and fundamental equations of image processing. *Archive for rational mechanics and analysis*, Springer, v. 123, n. 3, p. 199–257, 1993. Citado na página 54.
- AVINASH, S.; MANJUNATH, K.; KUMAR, S. S. An improved image processing analysis for the detection of lung cancer using gabor filters and watershed segmentation technique. In: IEEE. *International Conference on Inventive Computation Technologies (ICICT)*. [S.l.], 2016. v. 3, p. 1–6. Citado na página 27.
- BADDINI-MARTINEZ, J.; PEREIRA, C. A. Quantos pacientes com fibrose pulmonar idiopática existem no brasil? *Jornal Brasileiro de Pneumologia*, Jornal Brasileiro de Pneumologia, v. 41, n. 6, p. 560–561, 2015. Citado na página 27.
- BARROS, A. C. da S. *Optimum Path Snakes: Novo Método de Contornos Ativos Adaptativo e Não-Paramétrico*. Tese (Doutorado) — Universidade de Fortaleza, Fortaleza, CE, 2016. Citado 10 vezes nas páginas 15, 33, 34, 41, 42, 46, 49, 50, 53 e 62.
- BERTUOL, G. *Análise e aplicação da técnica de contornos ativos com métodos de segmentação tradicionais em imagens médicas*. Tese (Doutorado) — Universidade Federal de Santa Catarina, 2007. Citado 3 vezes nas páginas 43, 45 e 53.
- BRESSON, X. et al. Fast global minimization of the active contour/snake model. *Journal of Mathematical Imaging and vision*, Springer, v. 28, n. 2, p. 151–167, 2007. Citado na página 53.
- CAPITAL, V.-P. da et al. Protocolo de diagnóstico e tratamento de fibrose pulmonar idiopática da sociedade do estado do rio de janeiro. 2018. Citado na página 27.
- CASELLES, V.; KIMMEL, R.; SAPIRO, G. Geodesic active contours. *International journal of computer vision*, Springer, v. 22, n. 1, p. 61–79, 1997. Citado 7 vezes nas páginas 28, 29, 30, 43, 44, 56 e 67.
- CATTÉ, F.; DIBOS, F.; KOEPFLER, G. A morphological scheme for mean curvature motion and applications to anisotropic diffusion and motion of level sets. *SIAM Journal on Numerical Analysis*, SIAM, v. 32, n. 6, p. 1895–1909, 1995. Citado na página 55.
- CAVALCANTE, T. Técnica para segmentação automática de vias aéreas em imagens de tomografia computadorizada do tórax. *Fortaleza: Universidade Federal do Ceará*, 2010. Citado 2 vezes nas páginas 47 e 62.
- CHOI, S.-S.; CHA, S.-H.; TAPPERT, C. C. A survey of binary similarity and distance measures. *Journal of Systemics, Cybernetics and Informatics*, Citeseer, v. 8, n. 1, p. 43–48, 2010. Citado na página 52.

CID, Y. D. et al. Efficient and fully automatic segmentation of the lungs in ct volumes. In: *VISCERAL Challenge@ ISBI*. [S.l.: s.n.], 2015. p. 31–35. Citado 3 vezes nas páginas 15, 48 e 49.

COHEN, L. D. On active contour models and balloons. *CVGIP: Image understanding*, Elsevier, v. 53, n. 2, p. 211–218, 1991. Citado 2 vezes nas páginas 34 e 47.

DAVIS, J. A. et al. Image processing with the radial hilbert transform: theory and experiments. *Optics Letters*, Optical Society of America, v. 25, n. 2, p. 99–101, 2000. Citado na página 38.

DICE, L. R. Measures of the amount of ecologic association between species. *Ecology*, Wiley Online Library, v. 26, n. 3, p. 297–302, 1945. Citado na página 52.

EVANS, L. C.; SPRUCK, J. et al. Motion of level sets by mean curvature. i. *Journal of Differential Geometry*, Lehigh University, v. 33, n. 3, p. 635–681, 1991. Citado 4 vezes nas páginas 15, 44, 55 e 56.

FÉLIX, J. H. d. S. *Metodos de Contornos Ativos Hilbert 2D na segmentação de imagens dos pulmões em Tomografia Computadorizada do Tórax*. Tese (Doutorado) — Universidade Federal do Ceará, Fortaleza, CE, 2011. Citado na página 34.

FELIX, J. H. d. S. *Métodos de Contornos Ativos Hilbert 2D na segmentação de imagens dos pulmões em Tomografia Computadorizada do Tórax*. Tese (Doutorado) — Tese de Doutorado, Universidade Federal do Ceará, Fortaleza, CE, 2013. Citado na página 38.

FELIX, J. H. da S. et al. Avaliação computacional de enfisema pulmonar em TC: comparação entre um sistema desenvolvido localmente e um sistema de uso livre. *Jornal Brasileiro de Pneumologia*, SciELO Brasil, v. 35, n. 9, p. 868–876, 2009. Citado na página 27.

FELIX, J. H. S. *Sistema de Visão Computacional para Detecção e Quantificação de Enfisema Pulmonar*. Tese (Doutorado) — Dissertação de Mestrado, Universidade Federal do Ceará, Fortaleza, CE, 2007. Citado 2 vezes nas páginas 34 e 46.

FORTALEZA, S. Efeitos da administração de pressão positiva contínua em vias aéreas de modo não invasivo sobre a aeração do parênquima pulmonar em pacientes com doença pulmonar obstrutiva crônica. *Fortaleza: Universidade Federal do Ceará*, 2006. Citado na página 70.

GONZALEZ, R. C. *Digital image processing*. [S.l.]: Pearson Education India, 2009. Citado 4 vezes nas páginas 37, 53, 65 e 67.

HAUSDORFF, F. Bemerkung über den inhalt von punktmengen. *Mathematische Annalen*, Springer, v. 75, n. 3, p. 428–433, 1914. Citado na página 51.

HE, N. et al. Pulmonary parenchyma segmentation in thin ct image sequences with spectral clustering and geodesic active contour model based on similarity. In: INTERNATIONAL SOCIETY FOR OPTICS AND PHOTONICS. *Ninth International Conference on Digital Image Processing (ICDIP 2017)*. [S.l.], 2017. v. 10420, p. 104202G. Citado 4 vezes nas páginas 15, 47, 48 e 62.

- ILUNGA-MBUYAMBA, E. et al. Automatic selection of localized region-based active contour models using image content analysis applied to brain tumor segmentation. *Computers in Biology and Medicine*, v. 91, p. 69 – 79, 2017. ISSN 0010-4825. Citado na página 47.
- KASS, M.; WITKIN, A.; TERZOPOULOS, D. Snakes: Active contour models. *International journal of computer vision*, Springer, v. 1, n. 4, p. 321–331, 1988. Citado 3 vezes nas páginas 28, 33 e 40.
- KIM, S. E.; JEON, J. J.; EOM, I. K. Image contrast enhancement using entropy scaling in wavelet domain. *Signal Processing*, Elsevier, v. 127, p. 1–11, 2016. Citado na página 63.
- LAKSMI, T. et al. Novel image enhancement technique using clahe and wavelet transforms. *International Journal of Scientific Engineering and Technology*, Innovative Research Publications, v. 5, n. 11, p. 507–511, 2016. Citado na página 63.
- LAX, P. Numerical solution of partial differential equations. *The American Mathematical Monthly*, Taylor & Francis, v. 72, n. sup2, p. 74–84, 1965. Citado na página 53.
- LI, B.; ACTON, S. T. Vector field convolution for image segmentation using snakes. In: IEEE. *Image Processing, 2006 IEEE International Conference on*. [S.l.], 2006. p. 1637–1640. Citado 3 vezes nas páginas 28, 34 e 36.
- MACKIEWICH, B. *Intracranial boundary detection and radio frequency correction in magnetic resonance images*. Tese (Doutorado) — Theses (School of Computing Science)/Simon Fraser University, 1995. Citado 3 vezes nas páginas 34, 39 e 40.
- MARQUEZ-NEILA, P.; BAUMELA, L.; ALVAREZ, L. A morphological approach to curvature-based evolution of curves and surfaces. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, IEEE, v. 36, n. 1, p. 2–17, 2014. Citado 6 vezes nas páginas 15, 45, 53, 55, 56 e 67.
- MEDEIROS, A. G.; FERREIRA, D. S. Detecção de agrupamentos de microcalcificações em imagens digitais de mamografias. *Proceedings of the Brazilian Computer Society-SBC-XV WIM - Medical Informatics Workshop, Recife - PE, 2015*, 2015. Citado na página 27.
- MEDEIROS, A. G. et al. Uma nova abordagem para a segmentação de pulmões utilizando o método de contorno ativo não paramétrico optimum path snakes em imagens de tomografia computadorizada. Citado na página 28.
- NIXON, M.; AGUADO, A. S. *Feature extraction and image processing for computer vision*. [S.l.]: Academic Press, 2012. Citado na página 33.
- NÓBREGA, R. V. M. da; RODRIGUES, M. B.; FILHO, P. P. R. Segmentation and visualization of the lungs in three dimensions using 3d region growing and visualization toolkit in ct examinations of the chest. In: IEEE. *2017 IEEE 30th International Symposium on Computer-Based Medical Systems (CBMS)*. [S.l.], 2017. p. 397–402. Citado na página 27.
- OSHER, S.; SETHIAN, J. A. Fronts propagating with curvature-dependent speed: algorithms based on hamilton-jacobi formulations. *Journal of computational physics*, Elsevier, v. 79, n. 1, p. 12–49, 1988. Citado 2 vezes nas páginas 42 e 43.

- OTSU, N. A threshold selection method from gray-level histograms. *Automatica*, v. 11, n. 285-296, p. 23–27, 1975. Citado na página 65.
- PAPA, J. P.; FALCAO, A. X.; SUZUKI, C. T. Supervised pattern classification based on optimum-path forest. *International Journal of Imaging Systems and Technology*, Wiley Online Library, v. 19, n. 2, p. 120–131, 2009. Citado na página 41.
- PAUWELS, R. A. et al. Global strategy for the diagnosis, management, and prevention of chronic obstructive pulmonary disease. *American journal of respiratory and critical care medicine*, Am Thoracic Soc, 2012. Citado na página 27.
- PEREIRA, J. D. C. et al. *Médias: aritmética, geométrica e harmônica*. Tese (Doutorado) — Master's thesis, Universidade Estadual de Campinas, Campinas, SP, 2014. Citado na página 66.
- PIZER, S. M. et al. Adaptive histogram equalization and its variations. *Computer vision, graphics, and image processing*, Elsevier, v. 39, n. 3, p. 355–368, 1987. Citado na página 63.
- PNEUMOLOGIA, J. B. de. *Distância no teste de caminhada de seis minutos e sobrevida na fibrose pulmonar idiopática no Brasil*. 2019. Disponível em: <http://jornaldepneumologia.com.br/detalhe_artigo.asp?id=2824>. Citado na página 27.
- QIAN, X. et al. An active contour model for medical image segmentation with application to brain ct image. *Medical physics*, Wiley Online Library, v. 40, n. 2, 2013. Citado na página 52.
- RAPAKA, S.; KUMAR, P. R. Efficient approach for non-ideal iris segmentation using improved particle swarm optimisation-based multilevel thresholding and geodesic active contours. *IET Image Processing*, IET, v. 12, n. 10, p. 1721–1729, 2018. Citado na página 28.
- REBOUÇAS FILHO, P. P. *Mca crisp: nova técnica de segmentação dos pulmões em imagens de tomografia computadorizada baseada no método de contorno ativo*. Tese (Doutorado) — Universidade Federal do Ceará, Fortaleza, CE, 2010. Citado 10 vezes nas páginas 28, 34, 36, 37, 38, 39, 40, 46, 50 e 62.
- REBOUÇAS FILHO, P. P. *Métodos De Contornos Ativos Crisp Adaptativo 2D e 3D Aplicados Na Segmentação Dos Pulmões em Imagens De Tomografia Computadorizada Do Tórax*. Tese (Doutorado) — Tese de Doutorado, Universidade Federal do Ceará, Fortaleza, CE, 2013. Citado 5 vezes nas páginas 33, 37, 38, 39 e 40.
- REBOUÇAS FILHO, P. P. et al. 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. Citado na página 27.
- REBOUÇAS FILHO, P. P. et al. 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. Citado na página 34.

- REBOUÇAS FILHO, P. P. et al. Adaptive 2d crisp active contour model applied to lung segmentation in ct images of the thorax of healthy volunteers and patients with pulmonary emphysema. *Revista Brasileira de Engenharia Biomédica*, SciELO Brasil, v. 29, n. 4, p. 363–376, 2013. Citado 9 vezes nas páginas 15, 34, 35, 36, 46, 49, 50, 59 e 62.
- REBOUÇAS FILHO, P. P. et al. Modelo de Contorno Ativo Crisp Adaptativo 2D aplicado na segmentação dos pulmões em imagens de TC do tórax de voluntários sadios e pacientes com enfisema pulmonar. *Revista Brasileira de Engenharia Biomédica*. ISSN 1517-3151. Citado na página 28.
- REBOUÇAS FILHO, P. P. et al. Analysis of human tissue densities: A new approach to extract features from medical images. *Pattern Recognition Letters*, Elsevier, v. 94, p. 211–218, 2017. Citado na página 28.
- REBOUÇAS FILHO, P. P. et al. Analysis of human tissue densities: A new approach to extract features from medical images. *Pattern Recognition Letters*, p. –, 2017. ISSN 0167-8655. Citado 7 vezes nas páginas 28, 29, 48, 53, 59, 62 e 67.
- REBOUÇAS FILHO, P. P. et al. New approach to detect and classify stroke in skull ct images via analysis of brain tissue densities. *Computer Methods and Programs in Biomedicine*, v. 148, p. 27 – 43, 2017. ISSN 0169-2607. Citado na página 53.
- SOILLE, P. *Morphological image analysis: principles and applications*. [S.l.]: Springer Science & Business Media, 2013. Citado 3 vezes nas páginas 48, 54 e 67.
- SOOKPOTHAROM, S. Border detection of skin lesion images based on fuzzy c-means thresholding. In: IEEE. *3rd International Conference on Genetic and Evolutionary Computing, 2009. WGECC09*. [S.l.], 2009. v. 17, p. 777–780. Citado na página 56.
- WHO. *Chronic obstructive pulmonary disease (COPD)*. 2018. Disponível em: <<https://www.who.int/respiratory/copd/en/>>. Citado na página 27.
- 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. Citado 3 vezes nas páginas 28, 34 e 35.