

UNIVERSIDADE FEDERAL DE SANTA MARIA
CENTRO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA

Rafaelo Pinheiro da Rosa

**UMA TÉCNICA OTIMIZADA DE CLUSTERIZAÇÃO PARA
SEGMENTAÇÃO DE IMAGENS DE TC DE TÓRAX DE
ALTA-RESOLUÇÃO**

Santa Maria, RS
2016

Rafaelo Pinheiro da Rosa

**UMA TÉCNICA OTIMIZADA DE CLUSTERIZAÇÃO PARA SEGMENTAÇÃO DE
IMAGENS DE TC DE TÓRAX DE ALTA-RESOLUÇÃO**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Informática, Área de Concentração em Computação Aplicada, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do grau de **Mestre em Informática.**

ORIENTADOR: Prof. Marcos Cordeiro d'Ornellas

Santa Maria, RS
2016

Ficha catalográfica elaborada através do Programa de Geração Automática da Biblioteca Central da UFSM, com os dados fornecidos pelo(a) autor(a).

Pinheiro da Rosa, Rafaelo
Uma Técnica Otimizada de Clusterização para Segmentação de Imagens de TC de Tórax de Alta-Resolução / Rafaelo Pinheiro da Rosa.-2016.
62 p.; 30cm

Orientador: Marcos Cordeiro d\Ornellas
Dissertação (mestrado) - Universidade Federal de Santa Maria, Centro de Tecnologia, Programa de Pós-Graduação em Informática, RS, 2016

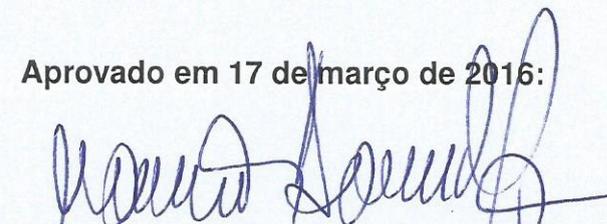
1. Segmentação de Imagens 2. Diagnóstico de Imagens Médicas 3. Tomografia Computadorizada I. Cordeiro d\Ornellas, Marcos II. Título.

Rafaelo Pinheiro da Rosa

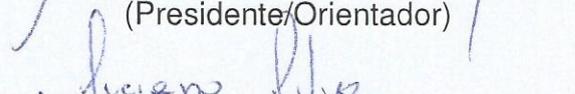
**UMA TÉCNICA OTIMIZADA DE CLUSTERIZAÇÃO PARA SEGMENTAÇÃO DE
IMAGENS DE TC DE TÓRAX DE ALTA-RESOLUÇÃO**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Informática, Área de Concentração em Computação Aplicada, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do grau de **Mestre em Informática**.

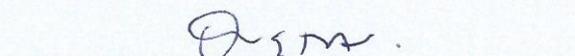
Aprovado em 17 de março de 2016:



Marcos Cordeiro d'Ornellas, Dr. (UFSM)
(Presidente/Orientador)



Luciano Silva da Silva, Dr. (FURG)



Gustavo Nogara Dotto, Dr. (UFSM)

Daniel Welfer, Dr. (UFSM)

Santa Maria, RS
2016

DEDICATÓRIA

Dedico este Mestrado ao meu pai, José Carlos Alves da Rosa e minha namorada, Edriéli Batista da Silva, pelo incentivo e apoio em todas as minhas escolhas e decisões.

*A vitória desta conquista dedico com todo o meu amor, unicamente, a vocês!
Parabéns!*

AGRADECIMENTOS

Agradeço, primeiramente, a DEUS, por estar sempre ao meu lado.

À minha família, por todos os momentos de alegria e descontração.

Ao meu orientador, Dr. Marcos Cordeiro d'Ornellas, por toda ajuda fornecida e ensinamentos adquiridos durante o trabalho.

Ao Prof. Carlos Jesus Pereira Haygert pelas indicações pontuais na pesquisa.

À empresa Animatei Computação Aplicada à Saúde, por toda ajuda fornecida para o ingresso no programa de mestrado.

Aos Doutores Gustavo Nogara Dotto e Luciano Silva da Silva, por aceitarem fazer parte da banca com as devidas correções.

À UFSM, professores e funcionários, que fizeram parte desta caminhada.

A todos vocês, muito obrigado!

A imaginação é mais importante que a ciência, porque a ciência é limitada, ao passo que a imaginação abrange o mundo inteiro.

(Albert Einstein)

RESUMO

UMA TÉCNICA OTIMIZADA DE CLUSTERIZAÇÃO PARA SEGMENTAÇÃO DE IMAGENS DE TC DE TÓRAX DE ALTA-RESOLUÇÃO

AUTOR: Rafaelo Pinheiro da Rosa

ORIENTADOR: Marcos Cordeiro d'Ornellas

Segmentação de tórax é um passo fundamental em muitas aplicações de análise de imagens para doenças de pulmão e anormalidades em tomografia computadorizada (TC) torácica. Contudo, devido às variações patológicas que podem estar presentes em imagens de TC, torna-se difícil extrair regiões do pulmão com precisão, especialmente quando o parênquima pulmonar possui certas regiões defeituosas. Uma forma de contornar este problema é a utilização de novas técnicas para obter qualidade e desempenho na segmentação pulmonar. Este trabalho apresenta uma técnica de clusterização otimizada de superpixels para a segmentação de imagens pulmonares de TC de alta-resolução. O algoritmo proposto é comparado contra alguns algoritmos de código aberto enquanto que o desempenho é avaliado em termos de métricas como boundary recall e under-segmentation error. Os resultados das imagens segmentadas sobre um conjunto de dados de imagens de enfisema de tomografia computadorizada demonstraram que a técnica proposta apresenta uma melhor performance do que outros três métodos de superpixels estado-da-arte.

Palavras-chave: Segmentação de Imagens. Diagnóstico de Imagens Médicas. Tomografia Computadorizada.

ABSTRACT

AN OPTIMIZED SUPERPIXEL CLUSTERING APPROACH FOR HIGH-RESOLUTION CHEST CT IMAGE SEGMENTATION

AUTHOR: Rafaelo Pinheiro da Rosa
ADVISOR: Marcos Cordeiro d'Ornellas

Lung segmentation is a fundamental step in many image analysis applications for lung diseases and abnormalities in thoracic computed tomography (CT). However, due to the large variations in pathology that may be present in thoracic CT images, it is difficult to extract the lung regions accurately, especially when the lung parenchyma contains extensive lung diseases. A major insight to deal with this problem is the existence of new approaches to cope with quality and performance. This paper presents an optimized superpixel clustering approach for high-resolution chest CT segmentation. The proposed algorithm is compared against some open source superpixel algorithms while a performance evaluation is carried out in terms of boundary recall and under-segmentation error metrics. The over-segmentation results on a Computed Tomography Emphysema Database demonstrates that our approach shows better performance than other three state-of-the-art superpixel methods.

Keywords: Image Segmentation. Medical Images Diagnosis. Computed Tomography.

LISTA DE FIGURAS

Figura 1.1 – Exemplo de segmentação de imagens médicas tomográficas.	11
Figura 3.1 – Exemplo da aplicação do corte mínimo.	23
Figura 3.2 – Exemplo da aplicação do NC.	24
Figura 3.3 – Exemplo de segmentação do NC.	25
Figura 3.4 – Exemplo de segmentação de TP.	26
Figura 3.5 – Exemplo de segmentação de QS.	28
Figura 4.1 – Fluxograma do algoritmo SLIC.	31
Figura 4.2 – Exemplo de uma redução na busca por <i>clusters</i> em uma região limitada.	32
Figura 4.3 – Exemplo de compactação utilizando-se a variável <i>m</i>	34
Figura 4.4 – Exemplo de uma aplicação do algoritmo de <i>Region Merging</i>	39
Figura 5.1 – Resultados para BR de imagens médicas.	43
Figura 5.2 – Resultados para USE de imagens médicas.	44
Figura 5.3 – Imagens geradas por cada um dos métodos de <i>superpixels</i>	45
Figura 5.4 – Resultados para BR de imagens coloridas.	46
Figura 5.5 – Resultados para USE de imagens coloridas.	47
Figura 5.6 – Comparação entre os resultados do <i>Region Merging</i>	48
Figura 5.7 – Imagem GT.	49
Figura 5.8 – Resultados para BR.	49
Figura 5.9 – Resultados para USE.	50
Figura 5.10 – Comparação com imagens médicas selecionadas com <i>Bounding-Box</i>	51

LISTA DE ABREVIATURAS E SIGLAS

<i>BR</i>	Boundary Recall
<i>CTED</i>	Computed Tomography Emphysema Database
<i>DAC</i>	Diagnóstico Auxiliado por Computador
<i>DPOC</i>	Doença Pulmonar Obstrutiva Crônica
<i>ESLIC</i>	Enhanced Simple Linear Iterative Clustering
<i>FH</i>	Felzenszwalb and Huttenlocher
<i>FN</i>	Falso-Negativo
<i>FP</i>	Falso-Positivo
<i>GPU</i>	Graphics Processing Unit
<i>GT</i>	Ground-Truth
<i>IS</i>	Imagem Segmentada
<i>MS</i>	Meanshift
<i>NC</i>	Normalized Cuts
<i>PET</i>	Positron Emission Tomography
<i>QS</i>	Quickshift
<i>RMN</i>	Ressonância Magnética Nuclear
<i>SLIC</i>	Simple Linear Iterative Clustering
<i>SPECT</i>	Single Photon Emission Computed Tomography
<i>TC</i>	Tomografia Computadorizada
<i>TP</i>	Turbopixels
<i>US</i>	Ultrasonografia
<i>USE</i>	Under-Segmentation Error
<i>WS</i>	Watershed

SUMÁRIO

1	INTRODUÇÃO	10
1.1	OBJETIVOS	12
1.1.1	Objetivos Específicos	13
1.2	REVISÃO BIBLIOGRÁFICA	13
2	IMAGENS MÉDICAS	15
2.1	RADIOGRAFIA	16
2.2	ULTRASONOGRAFIA	17
2.3	RESSONÂNCIA MAGNÉTICA NUCLEAR	17
2.4	TOMOGRAFIA COMPUTADORIZADA	18
3	SUPERPIXELS	20
3.1	DEFINIÇÃO	20
3.2	ALGORITMOS	22
3.2.1	Normalized Cuts	22
3.2.2	Turbopixels	23
3.2.3	Quickshift	26
3.2.4	Outros Algoritmos	28
4	METODOLOGIA	30
4.1	SIMPLE LINEAR ITERATIVE CLUSTERING	30
4.2	ESLIC	34
4.3	MÉTRICAS DE AVALIAÇÃO	36
4.3.1	Boundary Recall	37
4.3.2	Under-Segmentation Error	37
4.4	REGION MERGING	38
5	RESULTADOS	41
5.1	CONJUNTO DE IMAGENS	41
5.2	COMPARAÇÕES	42
5.3	OUTROS TESTES	45
5.4	DESEMPENHO NA SEGMENTAÇÃO	50
6	CONCLUSÃO	54
	REFERÊNCIAS BIBLIOGRÁFICAS	56

1 INTRODUÇÃO

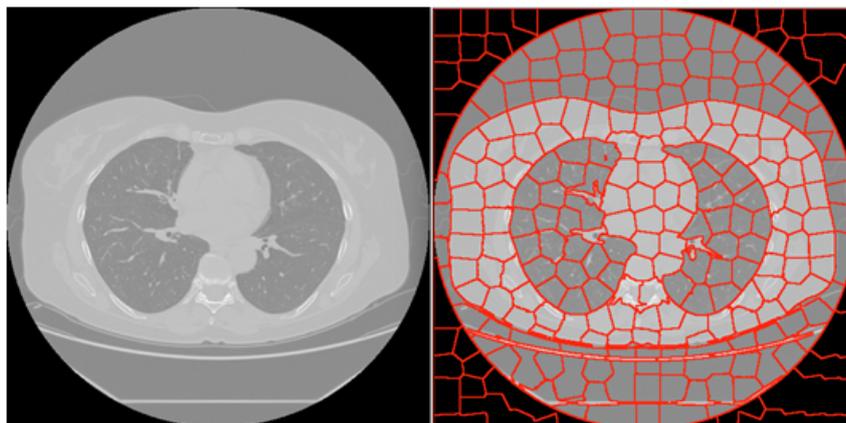
Os avanços na área de imageamento médico, nos últimos anos, transformaram-no em um componente indispensável em praticamente todos os ramos da medicina, fazendo com que este seja usado como uma ferramenta fundamental para o diagnóstico na maioria das práticas médicas (SMITH; WEBB, 2010). O diagnóstico radiológico é considerado, hoje em dia, um instrumento capaz de auxiliar as atividades de muitos médicos especialistas e de cuidados primários, sendo utilizado para facilitar a identificação de anomalias e permitir com que os tratamentos de doenças sejam mais eficazes por parte dos profissionais da saúde (SUETENS, 2009). Desta forma, as imagens médicas são utilizadas como um suporte de auxílio ao diagnóstico, permitindo com que determinadas anomalias sejam identificadas antes de manifestarem-se de uma forma atenuada.

Com o crescente uso de imageamento na maioria das áreas da medicina, surgiram técnicas de processamento e análise de imagens de forma a sistematizar e melhorar a precisão no diagnóstico realizado por profissionais da saúde. Por precisão de diagnóstico, entende-se como sendo um diagnóstico menos suscetível a erros e mais exato quanto à identificação da doença. A análise de imagens médicas, por meio de um sistema automatizado, auxilia no diagnóstico de anomalias (REKIK et al., 2012) (RODRIGUEZ-GONZÁLEZ, 2013), permitindo com que haja uma visualização e determinação mais clara de estruturas suspeitas de possíveis doenças. Ela não só identifica padrões anormais, mas também destaca esses padrões, podendo levar a um diagnóstico correto de defeitos anatômicos e distúrbios da função. Entretanto, o desenvolvimento e a evolução dos equipamentos de aquisição de imagens médicas, tais como a TC (Tomografia Computadorizada) e a RMN (Ressonância Magnética Nuclear), estão permitindo com que imagens sejam geradas com um tamanho maior, em termos de área, o que afeta o custo de armazenamento e desempenho computacional, necessário para o processamento destas imagens (ROCKALL et al., 2013). Como alternativa, uma técnica de pré-processamento poderia ser utilizada nestas imagens. Um exemplo desta técnica seria a segmentação, que permite destacar apenas a região de interesse do restante da imagem, levando com que o processamento computacio-

nal das informações seja feito restritamente nesta área. Isso poderia reduzir o tempo de execução do processamento da imagem, melhorando a eficiência do sistema em questão.

Apesar do vasto conhecimento em imagens médicas (JONES; XIE; ESSA, 2014), a segmentação ainda enfrenta muitos problemas técnicos e continua a ser um desafio na qualidade dos resultados gerados em relação às várias partes do corpo. Os modelos de reconstrução 3D para a anatomia do corpo, a partir de um conjunto de dados gerados por um tomógrafo ou um aparelho de ressonância magnética, dependem da segmentação precisa destas imagens e de um processamento geométrico. Como um exemplo, a Figura 1.1 apresenta uma fatia de TC de pulmão no lado esquerdo e sua correspondente segmentação no lado direito.

Figura 1.1 – Exemplo de segmentação de imagens médicas tomográficas.



Os modelos 3D de pulmão envolvem não somente um reconstrutor tridimensional realístico mas também uma análise detalhada e precisa das imagens 2D que compõe o conjunto de dados. Pequenas imprecisões na inclusão de nódulos justa pleurais poderiam levar a medições volumétricas imprecisas além de estimativas de doenças malignas (PU, 2008) (ZHOU; CHENG; TAMURA, 2014).

Recentemente, os *superpixels* surgiram como uma técnica fundamental e essencial em muitas aplicações de imagens, incluindo a segmentação (BERGH, 2012) (TANG; FU; CAO, 2012). Como *superpixels* são utilizados em um passo de pré-processamento para reduzir a complexidade de segmentação, eles devem ser computacionalmente eficientes, para evitar um impacto negativo no desempenho global. Este trabalho apresenta uma técnica de clusterização otimizada em *superpixels* para

uma melhor segmentação de imagens de TC de pulmão de alta-resolução. O algoritmo proposto é comparado contra outros métodos de *superpixels* de código aberto enquanto que a avaliação de desempenho é analisada em termos de métricas como BR (Boundary Recall) e USE (Under-Segmentation Error).

Os capítulos do trabalho são estruturadas, inicialmente, com uma descrição breve sobre alguns tópicos teóricos utilizados, como imagens médicas e *superpixels*, apresentando a metodologia, os resultados e a conclusão encontrados em seguida. O capítulo 2 apresenta uma breve descrição sobre o imageamento médico, explicando, também, sobre algumas das principais modalidades de aquisição de imagens, como a TC e a RMN. No capítulo 3, é apresentado o conceito de *superpixels*, juntamente com uma breve descrição sobre os principais algoritmos para a segmentação de imagens, como o NC (Normalized Cuts), TP (Turbopixels) e QS (Quickshift). No capítulo 4, são discutidos os assuntos relativos ao algoritmo proposto neste trabalho, bem como a técnica que originou o seu desenvolvimento. É apresentado também, neste capítulo, as métricas de avaliação utilizadas neste trabalho para analisar o desempenho da técnica desenvolvida. No capítulo 5, são mostrados e discutidos os resultados encontrados além de uma descrição sobre o conjunto de imagens médicas utilizadas. Por fim, no capítulo 6, é feita a conclusão do trabalho desenvolvido.

1.1 OBJETIVOS

Este trabalho teve como objetivo principal o desenvolvimento de uma técnica mais aprimorada para a segmentação de imagens médicas de TC de alta-resolução. Esta segmentação deve processar o devido destaque de estruturas internas de imagens médicas de pulmão, de forma que o delineamento resultante do procedimento corresponda da melhor forma possível com as bordas das regiões pulmonares de interesse. A técnica proposta foi implementada com base em um algoritmo de *superpixels* muito utilizado em trabalhos recentes.

1.1.1 Objetivos Específicos

- a) Implementar um método em Java que realize a segmentação de imagens diagnósticas;
- b) Buscar melhorar os resultados gerados pelo método desenvolvido;
- c) Comparar com imagens coloridas de um determinado banco de imagens.

1.2 REVISÃO BIBLIOGRÁFICA

O escaneamento em múltiplas fatias, a partir de um exame de tomografia, tem alterado a forma com que profissionais da saúde adquirem, processam e interpretam os dados originários do corpo humano, motivando cada vez mais o uso de técnicas de análise de imagens. No que diz respeito às imagens de TC de pulmão, a segmentação desta região é o primeiro passo importante para a devida análise quantitativa e para o DAC (Diagnóstico Auxiliado por Computador). Uma segmentação apropriada e precisa do pulmão permite melhores quantificações e detecções de anormalidades e malformações presentes nesta região. A segmentação de lóbulos é essencial para descobrir doenças do parênquima e para quantificar suas estruturas. Muitos métodos para a segmentação de imagens de tórax de TC, principalmente as de pulmão, foram propostos na literatura. A maioria deles é baseado no fato que um parênquima saudável apresenta uma larga diferença na atenuação entre o parênquima pulmonar e seus arredores.

Por exemplo, um algoritmo adaptativo de *border-matching* foi proposto em (BROWN, 1997)(PU, 2008). Mesmo assim, o algoritmo falha em alguns casos particulares devido a alguns erros no passo de pré-segmentação. Uma técnica refinada de segmentação foi discutida em (SLUIMER et al., 2006) e (RIKXOORT, 2009), resultando significativas melhorias de precisão na segmentação, mas passou a ser ineficiente devido a alguns processos de registro e classificação. A segmentação baseada na curvatura da costela foi proposta em (PRASAD, 2008), produzindo resultados mais precisos de segmentação. Todas estas abordagens têm deficiências que as tornam impraticáveis para o processamento de imagens pulmonares de TC de alta-resolução.

Um novo método para computar *supervoxels* em um ambiente 3D, a partir de um conjunto de dados de imagens radiológicas, foi proposto em (HOLZER; DONNER, 2014). Ele permite lidar com os altos níveis de ruído e de baixo contraste encontrados em dados clínicos de multimodalidade. Recentemente, foi proposta uma nova abordagem para a segmentação pulmonar patológica utilizando amostras de *supervoxels* em TC. Esta abordagem é baseada no método estado-da-arte do SLIC (Simple Linear Iterative Clustering) para gerar os *supervoxels* nas imagens de TC e criar uma grade ideal para as amostras (MANSOOR; BAGCI; MOLLURA, 2014).

2 IMAGENS MÉDICAS

A influência de imagens médicas na saúde está crescendo de forma constante (Siemens, 2016). Estas imagens podem ser entendidas como um procedimento que permite criar uma representação visual do interior do corpo para análises clínicas e intervenções médicas. Com esta técnica, é possível que especialistas da área da saúde encontrem anormalidades em determinados órgãos, antes destes se manifestarem de uma forma mais intensa. Desta forma, pode-se obter um diagnóstico mais preciso e realizar um tratamento adequado para a devida enfermidade. A finalidade das imagens médicas é auxiliar no diagnóstico de anomalias, fornecendo materiais para o suporte de terapias.

Entretanto, os exames médicos sofreram muitas mudanças desde 1865, quando o físico alemão Roentgen, descobriu uma radiação capaz de atravessar materiais, sendo absorvidos por eles e fixando-se em anteparos. Esta descoberta, conhecida como Raios-X, pode ser aplicada na medicina com a visualização de estruturas internas do corpo humano, permitindo um diagnóstico de anomalias. Desde então, a análise de imagens médicas vêm passando por um aperfeiçoamento no diagnóstico e tratamento de doenças, graças aos crescentes avanços nos processos de aquisição, processamento e armazenamento destas imagens.

Existem diversas modalidades capazes de realizar a aquisição de imagens. (MAINTZ; VIERGEVER, 1998) classificam estas modalidades em dois grupos: anatômicas e funcionais. O primeiro grupo, modalidades anatômicas, é utilizado para a identificação de morfologias, podendo ser Raios-X, TC, RMN, US (Ultrasonografia), entre outras. Já as modalidades funcionais estão diretamente relacionados com a captura de informação à respeito do metabolismo de uma determinada estrutura anatômica, incluindo-se cintilografia, SPECT (Single Photon Emission Computed Tomography), PET (Positron Emission Tomography), modalidades de medicina nuclear, entre outras.

Cada uma destas modalidades de imagens médicas são sensíveis a um ou mais materiais que constituem os seres da natureza. Desta forma, cada uma delas apresenta peculiaridades que são vantajosas para determinados tipos de análise. O diagnóstico pulmonar é uma das principais aplicações destas modalidades. Nódulos

pulmonares podem ocorrer intrinsicamente como câncer de pulmão, levando a crer que sua verificação e diagnóstico prévio podem combater ou amenizar esta incidência (ERONDU, 2011). Esta amenização pode ser favorecida com o monitoramento do tamanho do nódulo, sua densidade e suavização nas bordas, além de uma constante avaliação da situação, permitindo uma escolha mais eficaz no tratamento, caso houver, graças às informações coletadas (MURTHY, 1995) (ERONDU, 2011).

A descrição de algumas modalidades neste capítulo dedicam-se às modalidades anatômicas, como Radiografia, Ultrassonografia, Ressonância Magnética Nuclear e Tomografia Computadorizada. As seções a seguir apresentam uma descrição focada na formação de imagens médicas, sendo apresentadas algumas vantagens e desvantagens da utilização destas técnicas.

2.1 RADIOGRAFIA

Nesta modalidade, a imagem é formada através da interação entre os fótons de Raios-X com a matéria. Estes fótons sofrem certas atenuações decorrentes de uma absorção total ou parcial, durante o contato com o objeto. Esse nível de absorção depende dos elementos constituintes dos objetos. Isso ocorre principalmente nos casos de músculos, ossos e gordura do corpo humano, onde haverá diferentes absorções por parte dos fótons. Desta forma, serão geradas diferentes atenuações, e consequentemente, diferentes intensidades de radiação que atingem o anteparo onde a imagem será formada, resultando em diferentes tonalidades de cinza. Esta diferença em escala de cinza produz o contraste, o que facilita a identificação das estruturas anatômicas da parte do corpo.

Entretanto, é importante que haja um controle nesta modalidade, uma vez que estes Raios-X são compostos por radiação ionizante. O excesso desta radiação, quando em contato com o organismo humano, pode trazer sérios prejuízos.

2.2 ULTRASONOGRAFIA

Esta modalidade é baseada na reflexão do som, segundo (BRONSON, 2002) e (BEGA, 2001). A imagem é formada com a reflexão da onda sonora após o contato com a estrutura anatômica em análise. Nesta modalidade, as imagens são criadas com a utilização de faixas de frequências maiores que a audível pelo ser humano, por exemplo de 1 a 10MHz, em aplicações de diagnóstico médico.

Esta tecnologia é muito utilizada em diagnósticos de imagens médicas, por ser capaz de facilitar o rastreamento de doenças a partir de exames de órgãos como abdômen e estruturas superficiais (mama, tireóide, globo ocular e sistema músculo-esquelético). É um método não invasivo, com boa sensibilidade e baixo custo. Entretanto, possui como desvantagem a dependência da habilidade do operador em gerar imagens com boa qualidade, a baixa resolução espacial e a presença de ruídos na imagem. Além disso, o aparelho de ultra-som pode detectar a presença de ruídos de outros equipamentos, criando pontos ou faixas lineares na imagem, o que permite certas deformações e irregularidades, dificultando a análise do exame. As imagens são geradas em tons de cinza, e em tempo real, com um tamanho geralmente de $512 \times 512 \text{ pixels}$, sendo armazenadas em memória digital, videocassete, ou diretamente no filme através de uma câmera multiformato.

2.3 RESSONÂNCIA MAGNÉTICA NUCLEAR

Esta tecnologia baseia-se nas propriedades magnéticas dos núcleos atômicos (DAINTY; SHAW, 1976). Ela é capaz de fornecer um maior detalhamento anatômico do que as demais modalidades, apresentando também melhores informações estruturais e fisiológicas. Nas imagens geradas por esta técnica, é possível identificar os diversos tipos de tecidos moles, mesmo que estes apresentem a mesma densidade de massa.

A densidade local, encontrada no núcleo atômico, é uma das principais propriedades mapeadas durante a formação da imagem por RMN. O elemento mais utilizado, neste caso, é o hidrogênio, por estar presente, em grande parte, na composição do

corpo humano. Para a geração das imagens, uma sequência de pulsos de radio-frequência perturba uma amostra de núcleos atômicos, levando a uma emissão de RMN para cada um dos núcleos atingidos. Os sinais retornados são registrados para a formação da imagem, com grande diferenciação entre os tecidos.

Para a realização do exame, o paciente deve posicionar-se em um aparelho em formato de túnel, formado por bobinas magnéticas que fornecem a frequência necessária para o procedimento. Dentre as principais desvantagens desta técnica, estão a claustrofobia e o barulho gerado pelo equipamento, além de ser perigosa para pacientes que possuem alguns implantes metálicos, como marcapassos.

2.4 TOMOGRAFIA COMPUTADORIZADA

A TC é uma modalidade que permite a aquisição de imagens seccionadas do corpo humano, sem que haja órgãos anatômicos sobrepostos (BUZUG, 2008), permitindo com que os exames possuam numerosas fatias, com uma boa resolução espacial. A análise quantitativa de exames com um grande número destas fatias tem motivado o desenvolvimento de novas técnicas computacionais para realizar a segmentação de órgãos (TORRES, 2012).

Esta técnica é semelhante à radiografia convencional, diferenciando-se pelo fato dos Raios-X serem apenas absorvidos de forma parcial pelo corpo (WILKS, 1987). Na TC, os feixes de Raios-X são emitidos por uma pequena fenda, tendo a forma de leque. O paciente deve posicionar-se em um aparelho no formato de um túnel, que gira 360 graus ao redor da região do corpo a ser analisada, gerando uma imagem tomográfica. Cada imagem gerada representa uma fatia da região estudada. Em oposição aos feixes de Raios-X emitidos, existe um detector de fótons que gira simultaneamente aos feixes. Os fótons emitidos dependem da espessura dos objetos e da capacidade deste de absorver os Raios-X. Os fótons emitidos são transformados pelos detectores em sinais analógicos e depois em digitais. Após as seções transversais serem adquiridas, as informações são processadas com a utilização de técnicas matemáticas de reconstrução, como a *Transformada de Fourier*.

As imagens de TC são adquiridas em três planos: axial (perpendicular ao maior

eixo do corpo), coronal (visão frontal) e sagital (paralelo à satura sagital do crânio). Algoritmos de reconstruções tridimensionais podem ser aplicados para a geração de imagens em três dimensões, a partir das imagens geradas nestes três planos.

A principal vantagem da utilização da TC é o estudo de seções transversais do corpo, sendo, neste caso, superior à radiografia convencional, pois permite uma melhor detecção de anomalias. Dentre as desvantagens, pode-se destacar a grande quantidade de radiação dos Raios-X absorvidos pelo paciente. Outra desvantagem é seu elevado custo dentre as demais modalidades como a radiografia convencional.

3 SUPERPIXELS

Uma vez que o objetivo deste trabalho é uma implementação otimizada de um dos principais métodos de *superpixels*, seria necessário uma descrição breve sobre o conceito de *superpixels*, assim como uma explicação do modo de funcionamento dos principais algoritmos.

3.1 DEFINIÇÃO

Os *pixels* são considerados a base unitária em aplicações de processamento de imagens (Neubert, P. and Protzel, P., 2015). Muitos algoritmos de visão computacional utilizam-se destes *pixels* para formar uma estrutura rígida, o qual representará o resultado da devida segmentação. Contudo, com esta estrutura rígida, a dificuldade em melhorar a performance da segmentação cresce conforme o número de *pixels* aumenta em imagens de tamanho grande. Além disso, a estrutura rígida de representação de segmentação é apenas um artefato em processamento digital de imagens. Seria muito mais proveitoso a utilização de entidades significativas resultantes de um processo de agrupamento em alto-nível. Este agrupamento poderia ser caracterizado por diferentes atributos capazes de permitir com que os *pixels* fossem selecionados e inseridos em regiões homogêneas.

Desta forma, surge o conceito de *superpixels*, que pode ser entendido como um pequeno grupo de *pixels* com características homogêneas. Estas características podem ser definidas como a intensidade de cor que cada *pixel* assumiria, e a proximidade espacial entre os *pixels*, determinado por suas coordenadas na imagem. A representação da segmentação por *superpixels* pode provocar uma redução significativa no tempo de processamento, uma vez que o número de *superpixels* é muito menor que o número de *pixels*. Em outras palavras, é muito mais útil, e rápido, realizar o processamento em regiões homogêneas do que *pixel-a-pixel*. Desta forma, *superpixels* devem ser processados como se fossem *pixels*. Segundo (ACHANTA, 2012), algumas propriedades são desejadas para a geração dos *superpixels*, como as descritas

abaixo.

- a) Aderência às bordas: esta é uma das principais características para alcançar uma melhor qualidade na segmentação. A capacidade dos *superpixels* de aderirem com uma maior precisão às bordas dos objetos na imagem é um ponto fundamental, utilizado como um meio para avaliar o desempenho dos diversos métodos de segmentação;
- b) Eficiência: o tempo de processamento necessário para a geração dos *superpixels* deve ser realizado de forma ágil. Esta eficiência é conquistada na simples redução de complexidade nas imagens, com o processamento sendo feito sobre os *superpixels* ao invés dos inúmeros *pixels* que constituem a imagem;
- c) Redução da redundância: *superpixels* são significativamente perceptivos, uma vez que todos os *pixels* pertencentes ao mesmo *superpixels* são semelhantes em cor e proximidade espacial. Desta forma, existe uma redução na redundância com o agrupamento de *pixels* homogêneos em regiões maiores, capazes de diferenciar-se das demais pelas características que cada uma possui;
- d) Estruturas preservadas: uma vez que os *superpixels* são o resultado de um procedimento de “sobre-segmentação”, a maioria das estruturas dos objetos são preservadas nas imagens.

Os algoritmos de *superpixels* podem ser categorizados de duas formas: algoritmos baseados em grafo e algoritmos baseados no gradiente ascendente. O primeiro trata cada *pixel* como um nó pertencente a um grafo. O peso da aresta entre dois nós é proporcional à similaridade entre os *pixels* vizinhos. Os *superpixels* são gerados pela minimização da função de custo, definida sobre o grafo. Os principais algoritmos implementados com esta estratégia é o NC (SHI; MALIK, 2000) e FH (Felzenszwalb and Huttenlocher) (FELZENSZWALB; HUTTENLOCHER, 2004). Já o segundo refina iterativamente os *clusters* até algum critério de convergência ser atingido para criar os *superpixels*. Exemplos são o QS (VEDALDI; SOATTO, 2008), TP (LEVINSHTEIN et al., 2009), WS (Watershed) (VINCENT; SOILLE, 1991) e MS (Meanshift) (COMANICIU; MEER, 2002).

3.2 ALGORITMOS

Vários algoritmos de *superpixels* vêm sendo desenvolvidos ao longo dos últimos anos, com a finalidade de melhorar a qualidade do nível de segmentação. Nesta seção, são apresentadas breves discussões sobre o conceito de cada um dos métodos de *superpixels* utilizados neste trabalho.

3.2.1 Normalized Cuts

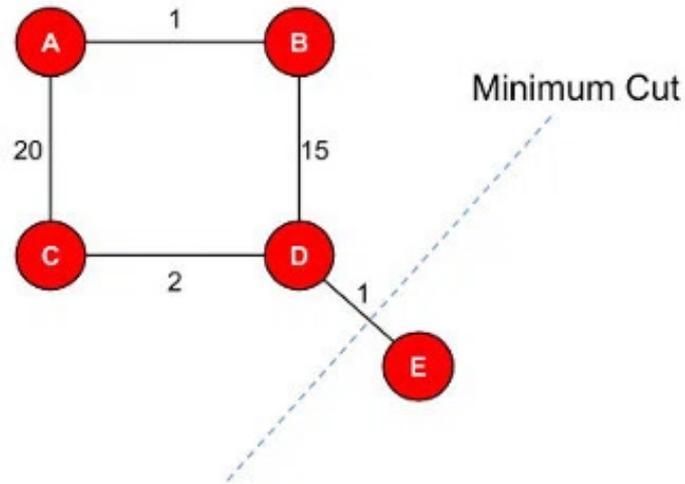
(SHI; MALIK, 2000) foram os primeiros a propor a utilização do algoritmo NC para realizar a segmentação de imagens. Inicialmente, a imagem é vista como sendo um modelo de grafo. O conjunto de *pixels* da imagem é representado por um grafo de pesos $G = (V, E)$, onde V representa os vértices correspondentes aos *pixels* da imagem, e E representa as bordas na forma de pesos, w . Cada um dos pesos $w(u, v)$, representa a medida de similaridade entre os nós u e v . O grafo G pode ser dividido em dois subgrafos distintos, A, B , $A \cup B = V$ e $A \cap B = \emptyset$, com a simples remoção das bordas que conectam as duas partes geradas. O grau de dissimilaridade entre estas duas partes pode ser processada através do total de pesos das bordas a serem removidas. Este cálculo é chamado de corte (*cut*):

$$cut(A, B) = \sum_{u \in A, v \in B} w(u, v). \quad (3.1)$$

Uma forma otimizada de bipartição do grafo pode minimizar o valor deste corte. Entretanto, existe uma certa dificuldade em encontrar o corte mínimo ideal para um número exponencialmente grande de partições. O problema em encontrar este corte mínimo está justamente no fato dele ter a tendência de separar as regiões isoladas do grafo, como pode ser visto na Figura 3.1, onde o grafo foi dividido em subgrafos (A, B, C, D) e (E) , o que pode ser indesejado na segmentação de imagens. Uma partição mais racional poderia ser (A, C) e (B, D, E) . Para contornar este problema, a técnica NC foi desenvolvida.

NC é definida como:

Figura 3.1 – Exemplo da aplicação do corte mínimo.



Fonte: Adaptado de (Birodkar, V., 2014).

$$NCut(A, B) = \frac{cut(A, B)}{Assoc(A, V)} + \frac{cut(A, B)}{Assoc(B, V)}, \quad (3.2)$$

$$Assoc(A, V) = cut(A, V) = \sum_{u \in A, v \in V} w(u, v), \quad (3.3)$$

$$Assoc(B, V) = cut(B, V) = \sum_{u \in B, v \in V} w(u, v). \quad (3.4)$$

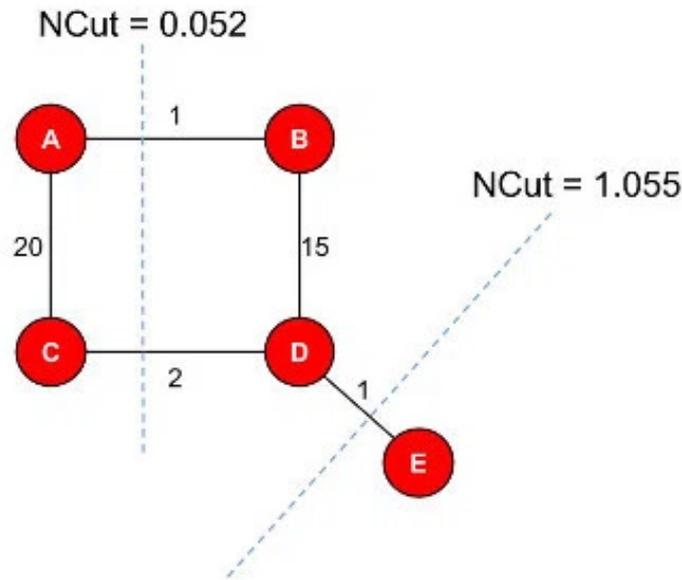
A partir das equações acima, pode-se visualizar que a minimização do NC produziu a partição esperada, na Figura 3.2.

A Figura 3.3 apresenta o resultado da segmentação produzida pelo NC.

3.2.2 Turbopixels

A técnica desenvolvida em (LEVINSHTEIN et al., 2009), para a segmentação de imagens em *superpixels*, é considerada um procedimento de fluxo geométrico. Esta técnica busca reduzir o tempo computacional através de uma eficiente solução de um problema encontrado em fluxos geométricos. A técnica é baseada em cinco

Figura 3.2 – Exemplo da aplicação do NC.



Fonte: Adaptado de (Birodkar, V., 2014).

princípios:

- Tamanho Uniforme e Aderência:** A principal característica de segmentação de *superpixels* é a divisão que ela provoca nas imagens, em regiões uniformes, quanto ao tamanho e forma. Isso pode resultar em regiões que não possuem uma cobertura precisa quanto às bordas dos objetos, uma vez que os *superpixels* gerados podem ser maiores ou menores que as regiões de interesse na imagem. A técnica TP soluciona este problema com um planejamento de fluxo geométrico que permite dilatar um conjunto inicial de pontos, distribuídos uniformemente, onde cada ponto corresponde a um *superpixel*, comportando-se inicialmente como bolhas de difusão e reação;
- Conectividade:** *Superpixels* devem possuir uma conectividade com um determinado conjunto de *pixels*. Esta garantia é alcançada através do fluxo baseado em dilatação, combinado com uma implementação fixada em níveis;
- Compactação:** *Superpixels* devem permanecer de forma compacta, quando na ausência de informação de borda. Para maximizar a compactação, foi incluído um método capaz de produzir movimentos constantes em direção à parte oposta do centro de regiões com intensidades uniformes, permitindo um aumento na taxa

Figura 3.3 – Exemplo de segmentação do NC.



de crescimento de área;

- d) Suavização: Quando o crescimento para, as bordas dos *superpixels* devem coincidir com as bordas dos objetos na imagem. Isto requer uma formulação no fluxo geométrico com três propriedades:
- Ele deve retardar o crescimento na vizinhança das bordas;
 - Ele deve ser atraído pelas bordas;
 - Ele deve produzir bordas suaves.

Para produzir esta suavização, foram introduzidas algumas formulações capazes de controlar o crescimento das bordas, incluindo um termo de curvatura para a regularização da forma do *superpixel*;

- e) Sem Sobreposição de *Superpixels* A segmentação baseada em *superpixels* deve assinalar todos os *pixels* como pertencentes a um único *superpixel*. Desta forma, o crescimento das bordas deve parar quando dois pontos em processo de dilatação distintos estão prestes a colidir. Para contornar este problema, foi adicionado um

mecanismo esquematizado que permite detectar a colisão, simultaneamente ao crescimento.

O principal objetivo desta técnica é a manutenção e o crescimento das bordas entre as regiões assinaladas, os quais contêm todos os *pixels* que já pertencem a algum *superpixel*. A Figura 3.4 apresenta uma imagem segmentada utilizando esta técnica. Os seguintes passos definem o algoritmo TP:

- a) Posicionar os pontos iniciais;
- b) Iterar sobre os passos abaixo até que a taxa de crescimento dos *pixels* de borda esteja próximo de zero:
 - Evoluir esta borda para os T intervalos de tempo;
 - Estimar a esquematização de regiões não assinaladas;
 - Atualizar a velocidade de cada *pixel* sobre as bordas e dos *pixels* não assinalados nas bordas imediatamente vizinhas;

Figura 3.4 – Exemplo de segmentação de TP.



3.2.3 Quickshift

Esta técnica foi introduzida por (VEDALDI; SOATTO, 2008), sendo considerado um algoritmo de modo de busca similar ao MS (COMANICIU; MEER, 2002), ou ao

medoid shift (SHEIKH; KHAN; KANADE, 2007). O algoritmo pode segmentar uma imagem colorida, ou qualquer outra imagem com mais de um canal, pela identificação de agrupamentos de *pixels* nas dimensões de cor e espaço (Fulkerson, B. and Vedaldi, A., 2007). A segmentação é local e pode ser usada em etapas de pós-processamento.

A partir de N pontos iniciais, x_1, \dots, x_N , a técnica calcula uma estimativa da densidade de Parzen sobre cada um dos pontos, utilizando, para isso, uma janela isotrópica como a *Gaussiana*

$$P(x) = \frac{1}{2\pi\sigma^2N} \sum_{i=1}^N e^{-\frac{\|x-x_i\|^2}{2\sigma^2}}. \quad (3.5)$$

Após isso, o algoritmo conecta cada um dos pontos ao ponto vizinho, em um espaço de características com uma alta densidade estimada, onde cada uma destas conexões possui uma distância d_x . As conexões de todos os *pixels* são organizadas em forma de uma árvore, onde sua raiz representa o ponto com maior densidade. Desta forma, o conjunto de *pixels* que compõem um ramo desta árvore, são rotulados com o valor da distância d_x . Isso permite especificar uma certa hierarquia na segmentação, com a geração de sub-árvores a partir destes segmentos. Os *superpixels* podem ser formados pelos cortes nestes ramos onde o valor da distância é menor que um determinado valor de limiar.

O algoritmo pode sofrer a influência de dois parâmetros:

- a) tamanho da janela: a densidade do *pixel* é determinada pela densidade de Parzen estimada por uma janela, como a *Gaussiana*, na qual, é especificada por um tamanho. Quanto maior for este tamanho, maior será a região da vizinhança dos *pixels* considerados;
- b) distância máxima: é a maior distância entre dois *pixels* que o QS considera durante a construção da árvore. Este valor pode ser infinito, mas quando aplicado em segmentação de imagens, ele deve ser pequeno, permitindo com que o algoritmo obtenha um melhor desempenho na velocidade da execução.

A Figura 3.5 apresenta um exemplo do resultado da segmentação após a aplicação do método QS.

Figura 3.5 – Exemplo de segmentação de QS.



3.2.4 Outros Algoritmos

Além das técnicas apresentadas anteriormente, outros algoritmos também foram desenvolvidos com a finalidade de segmentar imagens em *superpixels*. Um destes algoritmos foi proposto por (FELZENSZWALB; HUTTENLOCHER, 2004), como sendo uma alternativa para segmentação baseada em grafos. Ele trata um conjunto de *pixels* como sendo um nó de um grafo, tal que cada *superpixel* seja uma pequena árvore formada com seus *pixels* constituintes. Esta técnica possui uma complexidade de $O(N \log N)$, além de produzir resultados com uma boa aderência às bordas da imagem. Entretanto, produz *superpixels* com tamanhos e formas muito irregulares.

Uma outra técnica foi a desenvolvida por (MOORE, 2008), onde foi proposto um método para a segmentação, por meio de uma grade que divide a imagem em pequenas regiões horizontais e verticais. Os melhores caminhos são encontrados nesta grade, com a utilização de um algoritmo de cortes em um grafo, similar à técnica conhecida como *Sean Carving*. Este método possui uma complexidade de $O(N^{\frac{3}{2}} \log N)$.

Em (COMANICIU; MEER, 2002), foi proposta uma técnica de modo de busca iterativa para a localização de uma função de densidade local máxima. O algoritmo desenvolvido, conhecido como MS, é aplicado para encontrar tonalidades de cor ou intensidades nos espaços de características da imagem. *Pixels* que possuem tonalidades semelhantes são agrupados em um *superpixel*. Os resultados da segmentação, produzidos pelo MS, são geralmente irregulares, com um formato de *superpixel* não uniforme quanto ao tamanho.

A técnica WS, apresentada em (VINCENT; SOILLE, 1991), é um método muito conhecido de segmentação que produz linhas em uma imagem que separam regiões que lembram uma "bacia hidrográfica". Os *superpixels* resultantes desta técnica são muito irregulares em tamanho e forma, não possuindo uma boa aderência às bordas dos objetos.

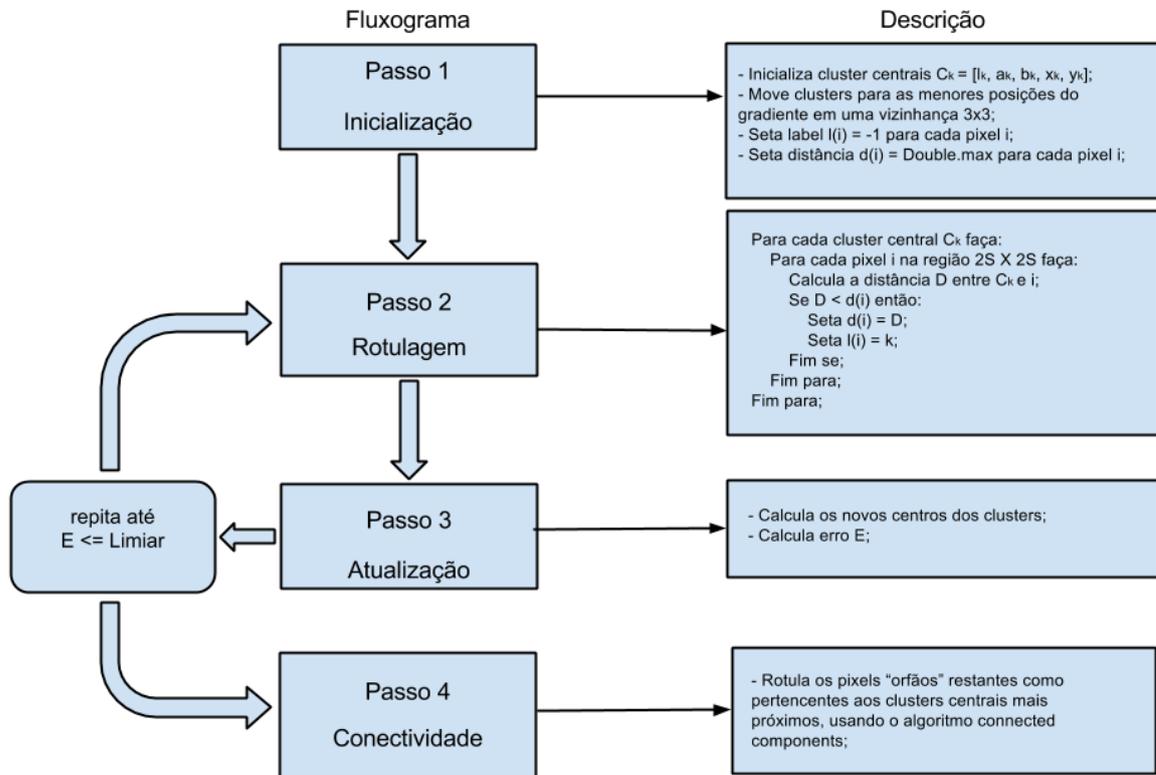
4 METODOLOGIA

Neste capítulo, será abordado o modo de funcionamento do SLIC, de uma forma bem descritiva, com figuras e um fluxograma de execução, mostrando o motivo dele ser um dos métodos mais utilizados recentemente para a segmentação de *superpixels*. Também será descrito quais mudanças foram feitas no SLIC para a geração da técnica desenvolvida neste trabalho, denominada de ESLIC (Enhanced Simple Linear Iterative Clustering), por ser uma versão mais otimizada, quanto à qualidade de segmentação. Como forma de avaliar o desempenho desta técnica implementada, serão usadas métricas padrões, utilizadas em outros trabalhos, como o BR e USE, ambas descritas na seção 4.3. Por fim, será apresentado o algoritmo do *Region Merging*, utilizado neste trabalho para melhorar a qualidade visual da segmentação da imagem após a execução do ESLIC.

4.1 SIMPLE LINEAR ITERATIVE CLUSTERING

Um dos métodos estado-da-arte para a segmentação de imagens em *superpixels*, o qual vêm sendo muito utilizado nos últimos anos, denomina-se SLIC (ACHANTA, 2012) (ACHANTA, 2010). Esta técnica é escolhida dentre as demais principalmente por ser de rápida execução e por apresentar os melhores resultados, como pode ser visto em (ACHANTA, 2012). Ela é uma versão simplificada do algoritmo *K-Means*, aplicado para a análise de *clusters* na área de mineração de dados. Os *superpixels* gerados pelo SLIC são mais compactos e permitem uma melhor aderência às bordas dos objetos na imagem, quando relacionados com os outros métodos. Uma outra vantagem desta técnica é a escolha oferecida ao usuário para determinar o número desejável de *superpixels* na imagem segmentada, o qual é configurada através do parâmetro k . Além desta configuração, o usuário também pode manipular o nível de compactação dos *clusters* gerados, através de um determinado parâmetro, comentado mais a frente. A Figura 4.1 apresenta um fluxograma do SLIC, contendo uma breve descrição do seu funcionamento.

Figura 4.1 – Fluxograma do algoritmo SLIC.



A primeira etapa do algoritmo é a inicialização, onde os k clusters iniciais são posicionados de forma a ocuparem espaços amostrados regularmente. Para isso, cada um dos *superpixels* terão tamanhos iguais,

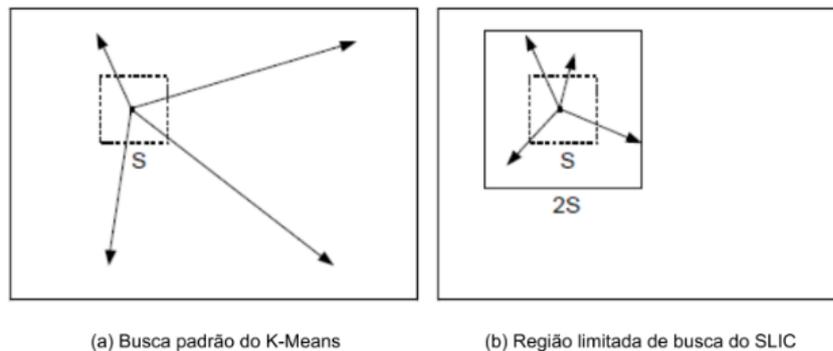
$$S = \sqrt{\frac{N}{k}}, \quad (4.1)$$

onde N é o número total de *pixels* da imagem e S é o tamanho do *superpixel* (ou seja, S corresponde ao número de *pixels* contidos em cada *cluster*). A raiz quadrada indica as dimensões de largura e altura de cada um dos *superpixels*, medida através da quantidade de *pixels*. Como forma de diminuir a possibilidade de que o centro de um *superpixel* fique sobre uma borda ou sobre um possível ruído, os centros dos *clusters* serão movidos para locais que correspondem à menor posição do gradiente, usando uma vizinhança 3×3 .

A segunda etapa do algoritmo é a rotulagem, onde cada um dos *pixels* da ima-

gem serão rotulados como pertencentes a um determinado *cluster*. Esta rotulagem é feita com base na distância do *pixel* em questão com o *cluster* mais próximo dentro de uma região limitada $2S \times 2S$, possibilitando uma melhor eficiência quanto ao tempo de execução quando comparado com o *K-Means*, onde cada *pixel* deve ser comparado com todos os *clusters* centrais, como pode ser visto na Figura 4.2. Com a busca por *clusters* dentro de uma região limitada, a complexidade do SLIC passa a ser linear em relação ao número de *pixels* da imagem $O(N)$, enquanto que o *K-Means* é $O(kNI)$, onde I corresponde ao número de iterações. O cálculo da distância é feito através de uma medida de similaridade apropriada com o objetivo de determinar o *cluster* central mais próximo para cada *pixel*.

Figura 4.2 – Exemplo de uma redução na busca por *clusters* em uma região limitada.



Fonte: Adaptado de (ACHANTA, 2012).

A medida de similaridade, para imagens coloridas, é a distância euclidiana, atuando em um espaço de cinco dimensões, formado por características relacionadas quanto à intensidade (l , a e b , correspondentes ao espaço de cor CIELAB) de cada *pixel* e sua posição espacial (x, y). Mesmo que todas as imagens testadas por este algoritmo tenham as mesmas dimensões e as mesmas variações em tonalidades nos canais RGB, estes valores podem variar para cada *cluster*, o que poderia gerar problemas no cálculo da distância. Como forma de reduzir as chances de classificar um *pixel* erroneamente, as distâncias espaciais d_s e de intensidade d_c devem ser normalizadas através de um valor máximo que elas devem assumir em cada *cluster*. Assim, o cálculo da distância euclidiana D fica

$$d_c = \sqrt{(l_j - l_i)^2 + (a_j - a_i)^2 + (b_j - b_i)^2}, \quad (4.2)$$

$$d_s = \sqrt{(x_j - x_i)^2 + (y_j - y_i)^2}, \quad (4.3)$$

$$D = \sqrt{\left(\frac{d_c}{N_c}\right)^2 + \left(\frac{d_s}{N_s}\right)^2}. \quad (4.4)$$

Uma vez que todos os *clusters* devem assumir valores máximos de tamanho equivalentes ao intervalo amostrado na etapa inicial do algoritmo, $N_s = S$. Para a definição do valor máximo de variação de intensidade em cada *cluster*, utiliza-se o parâmetro m . Este parâmetro corresponde ao nível de compactação que cada *superpixel* terá, podendo ser definido pelo usuário. Assim, aplicando estes valores na equação e simplificando-a, o cálculo de distância D fica

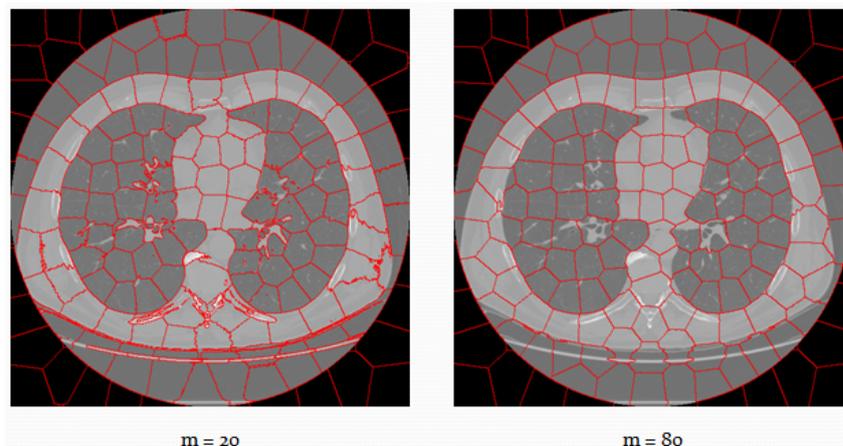
$$D = \sqrt{d_c^2 + f \cdot d_s^2}, \quad (4.5)$$

$$f = \left(\frac{m}{S}\right)^2. \quad (4.6)$$

Para valores altos de m , as distâncias espaciais passam a ser destacadas na equação, gerando *superpixels* mais compactos. Para valores menores, as distâncias de intensidade sobrepõe-se, permitindo gerar *superpixels* mais fiéis às bordas dos objetos na imagem. A Figura 4.3 apresenta duas imagens segmentadas pelo SLIC, onde utilizou-se valores diferentes para o parâmetro m . Na imagem da esquerda, percebe-se que a segmentação busca ser fiel com as bordas dos objetos enquanto que na imagem da direita, os *superpixels* tendem a ser mais compactos, com uma estrutura regular.

Na fase de atualização, os novos centros de cada *cluster* são calculados com base na média dos vetores de características (l, a, b, x, y) de cada *pixel* pertencente a um *cluster*. Nesta mesma etapa, ainda é utilizado o cálculo do valor de erro E entre os novos *clusters* centrais com os centros dos *clusters* anteriores. As etapas de rotulagem e atualização repetem-se até que este erro E direcione-se para um valor menor que um certo limiar estipulado. Entretanto, (ACHANTA, 2012) estipulou um número de iterações igual a dez como sendo ideal para a geração de resultados satisfatórios, ao invés de utilizar o cálculo de erro E como critério de parada do algoritmo.

Figura 4.3 – Exemplo de compactação utilizando-se a variável m .



Ao final desta fase, pode ocorrer de alguns *pixels* ficarem desmarcados (sem rótulo). Para isso, uma última etapa de conectividade deve ser realizada antes do resultado final da segmentação. Nesta fase, os *pixels* “orfãos” recebem o rótulo do *cluster* mais próximo à eles, através de uma técnica semelhante ao algoritmo *Connected Components Labeling*.

Percebe-se uma simplicidade no modo como o SLIC realiza seu processamento, como pode ser visto na descrição acima. Isso permite com que ele seja aplicado em muitos outros trabalhos além deste. Em (REN; REID, 2011), foi introduzida uma implementação paralela do SLIC, que usa GPU (Graphics Processing Unit) e NVIDIA CUDA, que alcança uma velocidade de 10 a 20 vezes mais rápida na execução que a implementação sequencial. Em (HSU; DING, 2013), o método é utilizado em um procedimento para realizar a segmentação de imagens, por meio do algoritmo *Region Merging*. No trabalho de (BOROVEC; KYBIC, 2014), foi desenvolvido um *plugin* para o *software* ImageJ, que segmenta a imagem por meio do SLIC, desenvolvido com algumas modificações de melhoria.

4.2 ESLIC

O algoritmo desenvolvido neste trabalho é uma versão mais simplificada e otimizada do SLIC. A implementação do ESLIC foi feita com o intuito de gerar imagens com uma melhor qualidade na segmentação. Entende-se, aqui, por uma melhor qua-

lidade de segmentação, a forma com que as bordas dos *superpixels* aderem-se com uma melhor precisão às bordas dos objetos da imagem em questão. Desta forma, não houve uma preocupação quanto à compactação dos *superpixels* e sim com a questão da aderência às bordas na imagem. Neste sentido, algumas modificações foram feitas no ESLIC, conforme descritas a seguir.

- a) Espaço de cor: No SLIC, todos os testes foram realizado com imagens no espaço de cor CIELAB, utilizando-se um vetor com cinco características para o cálculo da medida de similaridade, isto é, além da posição espacial (x, y) também é levado em consideração a tonalidade de cor dos *pixels* (l, a, b) , onde l é a luminosidade, e (a, b) são as coordenadas cromáticas. Como neste trabalho foram utilizadas principalmente imagens médicas de tomografia computadorizada, em níveis de cinza, o cálculo para a medição da similaridade acabou ficando mais simplificado, através de um vetor com apenas três atributos (l, x, y) , onde l corresponde ao nível de intensidade em tons de cinza de cada *pixel*;
- b) Distância Euclidiana: SLIC utiliza um parâmetro, representado na Equação 4.6, no cálculo da distância euclidiana, o que permite gerar *clusters* mais compactos, ou mais aderentes às bordas, dependendo do valor atribuído à variável m . Verificou-se nos testes realizados, que em determinados momentos, esse parâmetro não deve ser levado em consideração, o que ocorre poucas vezes. Assim sendo, adicionou-se um filtro que verifica, com base nos *pixels* que formam um *cluster*, se este parâmetro f deve ser considerado no cálculo da medida de similaridade. Este filtro é uma condição que analisa se o módulo da diferença do número máximo de *pixels* com mesma intensidade em um *cluster*, quando relacionado com o número total de *pixels* deste *cluster*, é menor que um valor estipulado de limiar. Se esta condição for falsa, então o parâmetro f é considerado, caso contrário não. O cálculo do filtro está mostrado abaixo:

$$|max - nt| < T, \quad (4.7)$$

onde max corresponde ao número máximo de *pixels* com intensidades iguais em um mesmo *cluster*, nt corresponde ao número total de *pixels* neste *cluster* e T é

o valor de Limiar. Estipulou-se que o valor de limiar escolhido para este trabalho seria igual a 100.

- c) Iterações: Na versão desenvolvida por (ACHANTA, 2012), observou-se que dez iterações podem ser usadas para a geração dos resultados, ao invés de aplicar-se o cálculo do erro como critério de parada. Neste trabalho, verificou-se que cinco iterações são capazes de gerar resultados bons visualmente, além de melhorar a performance do algoritmo quanto ao tempo de execução, uma vez que a implementação proposta corresponde à metade do número de iterações da versão original.
- d) Pós-processamento: Ao final do processamento do SLIC, é comum que alguns *pixels* estejam sem rótulo, permitindo com que estes estejam desconectados de todos os *clusters*. A versão original de (ACHANTA, 2012) corrige este problema utilizando um algoritmo de *Connected Components Labeling*, rotulando estes *pixels* como pertencentes aos *clusters* mais próximos. Entretanto, verificou-se nos testes, que todas as imagens utilizadas para a segmentação neste trabalho não apresentavam *pixels* sem rótulo após o processamento do ESLIC. Isso fez com que esta etapa de pós-processamento fosse removida do ESLIC.

4.3 MÉTRICAS DE AVALIAÇÃO

Superpixels são conhecidos por serem um procedimento para a segmentação de imagens, tendo como objetivo a representação de uma imagem de forma que reduza a variabilidade espectral dos *pixels* entre os *clusters*. Entretanto, grande parte dos *superpixels* localizam-se no interior de regiões significativas da imagem. Como forma de avaliar o desempenho da técnica desenvolvida, utiliza-se métricas de avaliação com o objetivo de extrair informações numéricas de um determinado método para futuras comparações. Desta forma, as duas métricas padrões utilizadas são o BR e o USE. Ambas permitem realizar a comparação entre uma imagem gerada por um determinado método de segmentação com uma imagem GT (*ground-truth*), isto é, com uma segmentação desejada, resultando em um valor numérico que dirá o quão próximas estão as segmentações comparadas.

4.3.1 Boundary Recall

A métrica padrão para BR avalia a quantidade de *pixels* presentes em bordas da imagem GT de objetos que sobrepõem-se a, pelo menos, um ou dois *pixels* de borda dos *superpixels*. Para valores próximos de 1, resultantes da aplicação desta métrica, corresponde que a precisão dos *superpixels* condizem com as bordas dos objetos da imagem GT. Dada uma imagem *GT* e uma imagem segmentada (*IS*) por um determinado método de *superpixel*. Então, FP (Falso-Positivo) é a quantidade de *pixels* de borda em *GT* interseccionados com *pixels* de borda existentes em *IS*. FN (Falso-Negativo) é o número de *pixels* de borda em *GT* para os quais não existe correspondência com os *pixels* de borda de *IS*. A métrica BR é dada pela equação abaixo:

$$BR(IS, GT) = \frac{TP(IS, GT)}{TP(IS, GT) + FN(IS, GT)}. \quad (4.8)$$

4.3.2 Under-Segmentation Error

A métrica USE avalia a quantidade de *pixels* de borda existentes nos *superpixels* que não fazem parte das bordas da imagem GT. Em outras palavras, ela mede a fração dos segmentos GT que são cobertos por um grupo de *superpixels*, impondo penalidades aos *superpixels* que não sobrepõem-se às bordas destes segmentos. A noção desta métrica é de certa forma oposta ao BR. Quanto mais próximo de 0 for o resultado gerado por esta métrica, melhor será a aderência das bordas dos *superpixels* com as bordas da imagem GT. A métrica USE é dada pela equação abaixo:

$$USE(IS, GT) = \frac{1}{N} \sum_{GT_i \in GT} \left(\sum_{IS_j \cap GT_i \neq \emptyset} \min \{ |IS_j \cap GT_i|, |IS_j - GT_i| \} \right). \quad (4.9)$$

4.4 REGION MERGING

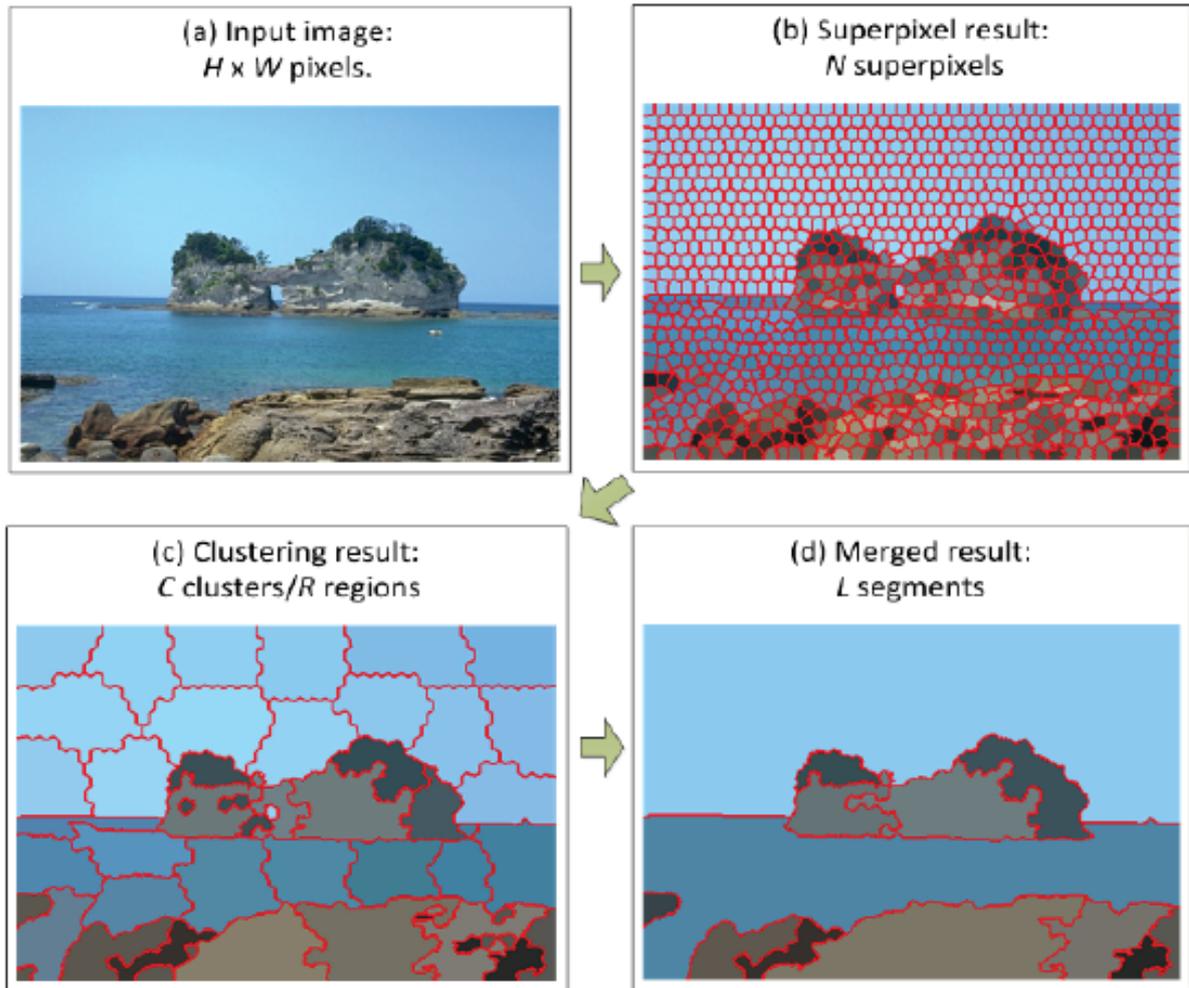
Com o intuito de melhorar a segmentação produzida pelo ESLIC, percebeu-se que muitos *superpixels* gerados possuíam as mesmas características, além de fazerem parte do mesmo objeto. Assim sendo, optou-se em utilizar um algoritmo de agrupamento de regiões semelhantes, cuja técnica é conhecida como *Region Merging*, de forma a eliminar, ou reduzir, a redundância gerada pelo ESLIC. Este procedimento foi realizado apenas para fins visuais, não havendo nenhum teste de desempenho ou avaliação sobre o método desenvolvido para tal finalidade.

O método utilizado para realizar o agrupamento de regiões seguiu o procedimento apresentado em (HSU; DING, 2013), onde foram adotadas as técnicas do SLIC, *5-D Spectral Clustering* e *Boundary-Focused Region Merging*, nesta ordem, para alcançar a segmentação, conforme pode ser observado na Figura 4.4. Segundo (HSU; DING, 2013), com esta técnica, é possível que a imagem segmentada resulte de forma mais consistente com a percepção humana. Os resultados encontrados, após testes com o banco de dados (MARTIN et al., 2001), demonstraram que a técnica em questão é mais eficiente que outros métodos estado-da-arte. Entretanto, apenas com a implementação do método *Spectral Clustering 5-D*, os resultados quanto a melhoria visual no processo de segmentação puderam ser alcançados, nas imagens testadas.

Após a aplicação do algoritmo SLIC, utiliza-se a técnica do *5-D Spectral Clustering* que irá agrupar *superpixels* com características muito parecidas, pertencentes ao mesmo objeto na imagem. Este algoritmo, quando aplicado para realizar diretamente a segmentação de imagens, em uma granularidade fina (em níveis de *pixels*), possui complexidade de $O(N^{\frac{3}{2}})$, onde N corresponde ao número de *pixels*. Entretanto, com a aplicação desta técnica em imagens de tamanho maior, ela pode requerer mais tempo para executar. Contudo, utilizando-se este método em uma imagem já segmentada em *superpixels*, o valor de N passa a corresponder aos *clusters* gerados, em uma granularidade mais grossa (em níveis de *superpixels*), levando a uma redução significativa no tempo computacional.

Inicialmente, é construído um grafo para representar os t vizinhos mais próximos. Para a criação deste grafo, são extraídas o conjunto de características referentes a cada *superpixel*: os valores médios de L , a , b no espaço de cor CIELAB, além dos valores médios de (x, y) das coordenadas espaciais.

Figura 4.4 – Exemplo de uma aplicação do algoritmo de *Region Merging*.



Fonte: Adaptado de (HSU; DING, 2013).

A partir de N *superpixels*, o grafo dos t vizinhos mais próximos é representado por uma matriz de similaridade $N \times N$, onde cada entrada desta matriz corresponde à similaridade entre dois *superpixels*. A medida de similaridade utilizada para comparar o i -ésimo *superpixel* com o j -ésimo é determinada pela distância euclidiana no espaço 5-D:

$$D_{i,j} = \sqrt{(l_i - l_j)^2 + (a_i - a_j)^2 + (b_i - b_j)^2 + \left(\frac{x_i - x_j}{SW}\right)^2 + \left(\frac{y_i - y_j}{SW}\right)^2}, \quad (4.10)$$

onde o conjunto (L, a, b) são os valor médios de cor e o par (x, y) são os valores médios de posição de um determinado *superpixel*. Já SW corresponde a um peso

utilizado para normalizar as médias espaciais, sendo dada pela equação abaixo:

$$SW = \frac{\sqrt{H \times W}}{m}, \quad (4.11)$$

com H e W sendo a altura e largura, respectivamente da imagem e m uma constante fixada em 100. Para maiores valores de m , significa que o grafo dos t vizinhos mais próximos terá as posições espaciais sobrepondo-se às informações de cor, enquanto que para menores valores ocorre o inverso. Na próxima etapa, são escolhidos os t *superpixels* mais próximos, para cada *superpixel*, criando-se uma nova matriz de similaridade MS , conforme definida abaixo:

$$MS_{i,j} = \begin{cases} \exp\left(\frac{-D_{i,j}^2}{2\sigma_i\sigma_j}\right), & \text{caso } i \text{ e } j \text{ sejam vizinhos,} \\ 0, & \text{em outro caso} \end{cases} \quad (4.12)$$

$$\sigma_i = \frac{1}{t} \sum_{k \in T} D_{i,k}, \quad (4.13)$$

onde o *superpixel* k pertence ao conjunto T dos t vizinhos mais próximos do *superpixel* i . Por questões de eficiência, o número de vizinhos mais próximos para cada *superpixel* foi configurado com 5.

5 RESULTADOS

A avaliação de desempenho do algoritmo ESLIC é apresentado nesta seção, para a comparação de sua precisão contra as versões dos algoritmos SLIC, TP, NC e QS. Toda a implementação do método foi realizada com a linguagem de programação Java, enquanto que a avaliação foi feita através de um *benchmark* implementado em MATLAB, contendo as métricas BR e USE. Este capítulo começa apresentando os conjuntos de imagens utilizados neste trabalho. Após isso, são descritas as comparações entre cada um dos métodos escolhidos para analisar o desempenho da técnica implementada. Apresenta ainda, outros testes feitos como as comparações com imagens coloridas e os resultados obtidos após a aplicação do algoritmo do *Region Merging*. Por fim, é feita uma breve análise do desempenho de cada método nas comparações.

5.1 CONJUNTO DE IMAGENS

O conjunto de imagens escolhido para a avaliação da performance do algoritmo ESLIC foi o CTED (Computed Tomography Emphysema Database) (SORENSEN; SHAKER; BRUIJNE, 2010). Este banco de imagens pode ser usado livremente para projetos educacionais e de pesquisa. A base deste banco contém 115 fatias de TC de alta-resolução, bem como 160 *patches*, os quais foram manualmente selecionados por um experiente radiologista pulmonar e por um pulmonologista experiente de TC. As fatias foram reconstruídos através de um algoritmo de resolução espacial. Estas fatias fazem parte de um grupo de estudos consistindo de 39 sujeitos (9 não fumantes, 10 fumantes e 20 fumantes com DPOC, Doença Pulmonar Obstrutiva Crônica). As fatias, de tamanho 512×512 , foram adquiridos nas faixas alta, média e baixa do pulmão de cada paciente.

Embora o objetivo deste trabalho seja a implementação de uma técnica mais otimizada, baseada no algoritmo SLIC, para realizar a segmentação de imagens médicas, seria interessante que, além dos testes feitos com imagens em níveis de cinza,

também houvessem testes com imagens coloridas, para avaliar e comprovar o desempenho do método desenvolvido. Com isso, os métodos escolhidos também foram avaliados com o conjunto de imagens fornecidos por (MARTIN et al., 2001), muito utilizado, recentemente, em trabalhos que envolvem a segmentação realizadas por métodos de *superpixels*. Este banco de imagens contém cerca de 300 imagens coloridas, de tamanho 481×312 , contendo aproximadamente 10 segmentações manuais (*ground truth*) para cada imagem, feitas por, pelo menos, quatro pessoas.

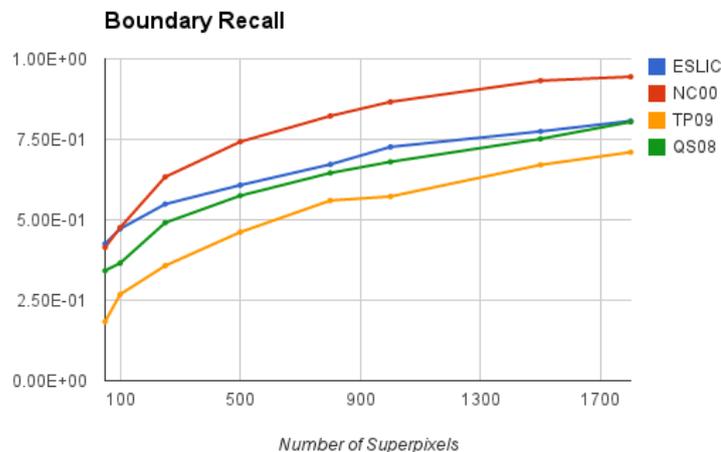
5.2 COMPARAÇÕES

Inicialmente, foram realizadas comparações, em termos das métricas de avaliação descritas anteriormente, com imagens médicas de tomografia. Os métodos de *superpixels* escolhidos para participarem destas comparações são: TP (TP09), QS (QS08), NC (NC00) e SLIC. Contudo, para fazer as comparações utilizando o BR e o USE, seria necessário possuir, primordialmente, uma imagem com a segmentação desejável, denominada de *ground truth*. Entretanto, o conjunto de dados providos pelo CTED, não fornecem nenhuma imagem de TC com uma segmentação *ground truth*. Seria necessário que um experiente radiologista de TC contribuísse para a geração de um conjunto de imagens GT. Uma outra alternativa seria determinar a imagem com a segmentação desejável como sendo a produzida por um dos métodos de *superpixels* escolhidos para as comparações. Devida à simplicidade da segunda opção e as dificuldades burocráticas, em termos de tempo, para entrar em contato com um radiologista, optou-se pela segunda alternativa. Neste caso, a imagem gerada pelo SLIC foi elegida como sendo a *ground truth*, uma vez que os resultados alcançados por este método foram superiores em relação aos demais, conforme pode ser observado em (ACHANTA, 2012). Assim sendo, as imagens geradas pelo ESLIC, TP, QS e NC foram comparadas contra a imagem GT, gerada pelo SLIC, utilizando as métricas de avaliação. A imagem produzida pelo SLIC foi segmentada com 100 *superpixels* e com um fator de compactação configurado em 20. Foram geradas oito imagens por cada um dos métodos, contendo 80, 100, 200, 500, 800, 1000, 1500 e 1800 *superpixels*.

A Figura 5.1 apresenta os resultados alcançados pela métrica BR. Nesta fi-

gura, conforme os valores aumentam, chegando perto de 1, significa que a imagem segmentada em questão está próxima da segmentação desejável. Percebe-se que nos 80 *superpixels*, o método ESLIC consegue ser melhor do que os outros três métodos, possuindo uma pequena vantagem de superioridade em relação ao NC. Quando a comparação é analisada com imagens de 100 *superpixels*, verifica-se que esta vantagem superior entre o ESLIC e o NC não existe mais, permanecendo os dois com a mesma qualidade de segmentação. No intervalo de 100 à 1500 *superpixels*, o gráfico comporta-se de forma praticamente uniforme, com o método NC sendo o de melhor representatividade, e com o ESLIC sendo superior ao TP e QS. Entretanto, neste intervalo, observa-se que a técnica QS possui uma pequena inferioridade que o ESLIC, possuindo valores próximos aos alcançados pela técnica proposta neste trabalho. Esta inferioridade é cessada quando são comparadas as imagens geradas com 1800 *superpixels*, onde percebe-se que estes dois métodos apresentam o mesmo valor para a métrica analisada, entretanto, o método NC permanece com os melhores resultados.

Figura 5.1 – Resultados para BR de imagens médicas.



Já os resultados para a métrica USE são apresentados na Figura 5.2. Ao contrário do que ocorre com a métrica anterior, valores chegando próximos à 0 indicam que, entre a imagem GT e a imagem segmentada por um determinado método, existem poucas diferenças quanto à qualidade de segmentação. Neste sentido, percebe-se que, com 80 *superpixels*, o método que apresenta melhores resultados é o QS, sendo o ESLIC inferior a todas as técnicas. Com 100 *superpixels*, o comportamento

do gráfico altera-se, sendo o TP o de melhor qualidade de segmentação, e o ESLIC ainda inferior do que às demais. O gráfico volta a alterar-se com 200 *superpixels*, onde verifica-se que os métodos ESLIC, NC e TP apresentam valores praticamente iguais, tendo o QS como sendo o inferior. De 500 a 800 *superpixels*, o método que se destaca com superioridade é o TP, com o ESLIC sendo superior do que o NC e o QS. O método ESLIC consegue ser superior do que às demais versões no intervalo de 1000 à 1500 *superpixels*, tendo uma pequena superioridade em relação ao TP. Entretanto, com 1800 *superpixels*, observa-se que o método TP volta a ter uma melhor segmentação, com o ESLIC possuindo uma pequena diferença à ele, mas sendo superior ao NC e QS.

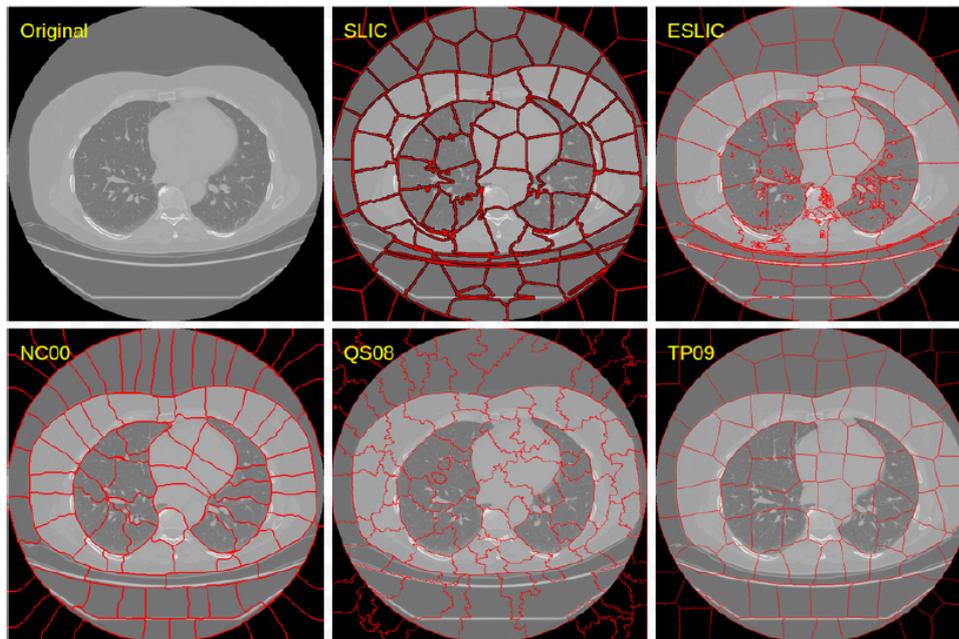
Figura 5.2 – Resultados para USE de imagens médicas.



Por uma questão de clareza, a Figura 5.3 apresenta as imagens geradas pela segmentação de cada um dos métodos, para efeitos de uma comparação mais voltada para o lado visual. É possível observar nesta figura, que o resultado produzido pela técnica desenvolvida neste trabalho, consegue segmentar melhor as estruturas internas do pulmão, o que pode ser considerado fundamental, quando pensado na aplicação de um sistema capaz de detectar possíveis anomalias no órgão. Os outros métodos escolhidos, inclusive o SLIC, não conseguem atingir este objetivo. É importante destacar novamente, que o principal motivo da implementação do ESLIC foi de melhorar a qualidade de segmentação produzida pelo método original, não preocupando-se com o fator de compactação de cada *superpixel*. Desta forma, percebe-se que os

superpixels gerados pela técnica proposta não seguem um padrão de forma definido pela compactação, visando apenas a correta aderência às bordas dos objetos de uma determinada imagem, ou, neste caso, às estruturas internas presentes no pulmão, uma vez que é nesta região onde encontra-se uma maior evidência de nódulos cancerígenos.

Figura 5.3 – Imagens geradas por cada um dos métodos de *superpixels*.



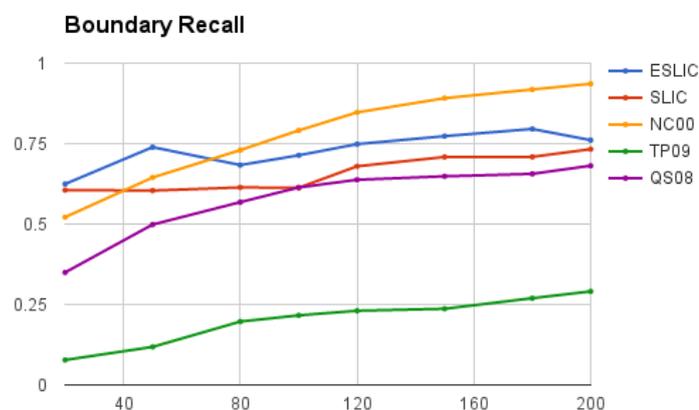
5.3 OUTROS TESTES

Além dos testes feitos com as imagens de CTED, também foram realizadas comparações com imagens coloridas, pertencentes ao conjunto de imagens providas por (MARTIN et al., 2001). As comparações com este conjunto de imagens foram feitas com o objetivo de avaliar o desempenho da técnica proposta com imagens coloridas. Este conjunto de imagens é muito utilizado em trabalhos que envolvam técnicas de segmentação, principalmente os de *superpixels*, como demonstrado em (ACHANTA, 2012). Devido a isso, optou-se em utilizar as imagens fornecidas por este banco, com o intuito de analisar a qualidade de segmentação do ESLIC, quando comparado aos outros métodos de *superpixels*, escolhidos para este trabalho. Este banco

de imagens, diferentemente do CTED, fornece imagens GT, o que torna ainda mais vantajoso a utilização deste conjunto de imagens, uma vez que os resultados para o ESLIC podem ser comparados, não só com os demais métodos (TP, QS e NC), mas também com o próprio SLIC, comparação esta que não pode ser observada nas comparações com imagens médicas, pela falta de imagens GT. Para a realização desta análise, foram geradas imagens segmentadas com 20, 50, 80, 100, 120, 150, 180 e 200 *superpixels*. As métricas de avaliação foram as mesmas utilizadas anteriormente.

A Figura 5.4 apresenta os resultados obtidos com a métrica BR. Neste gráfico, percebe-se que a técnica ESLIC mostrou melhores resultados que as demais versões, quando comparadas imagens com 20 e 50 *superpixels*. Entretanto, a partir de imagens com 80 *superpixels*, o gráfico altera o comportamento, tendo o método NC destacando-se de forma superior das demais versões. Contudo, os resultados para o ESLIC mantém um certo grau de superioridade em relação ao SLIC e às demais versões. Neste mesmo gráfico, é possível observar que o método TP apresentou piores resultados do que os demais métodos. Desta forma, o comportamento do gráfico com imagens coloridas foi semelhante ao encontrado com imagens médicas, com o método NC sendo superior a todas as versões, o TP sendo o inferior, e o ESLIC apresentando melhores qualidades de segmentação, quando comparados com o QS e o TP.

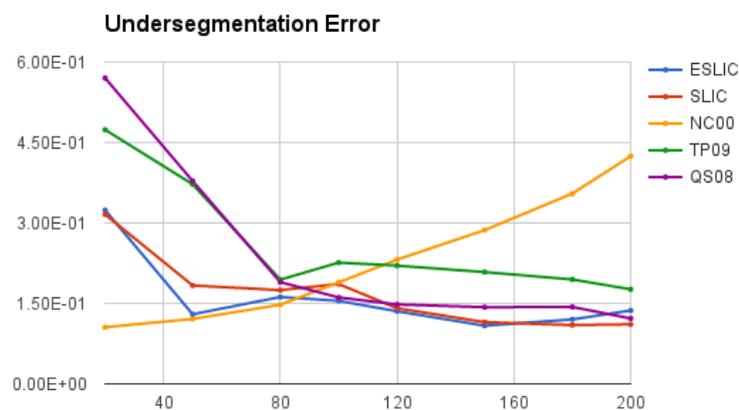
Figura 5.4 – Resultados para BR de imagens coloridas.



Já na Figura 5.5, os resultados para a métrica USE são mostradas. O gráfico

apresenta um comportamento diferente em relação ao gráfico para imagens médicas. Ao contrário das demais versões, o método NC apresenta uma piora na qualidade de segmentação, conforme o número de *superpixels* vai aumentando. Para 20 *superpixels*, este mesmo método apresentou melhores resultados do que os outros, havendo uma pequena semelhança entre os resultados do ESLIC e SLIC, entretanto, ambos sendo superiores ao TP e QS. Para 50 e 80 *superpixels*, o resultado do ESLIC aproxima-se do NC, mantendo uma pequena diferença para este método, apresentando, no entanto, melhores qualidades de segmentação do que o SLIC, TP e QS. Entre 100 e 150 *superpixels*, a técnica ESLIC destacou-se entre as demais, por apresentar melhores resultados. Entretanto, com 100 *superpixels*, revela-se uma pequena vantagem do ESLIC sobre o QS e com 120 e 150 *superpixels*, uma pequena vantagem sobre o SLIC. De 180 a 200 *superpixels*, o SLIC passa a ser o que apresenta melhores qualidades de segmentação, tendo o ESLIC resultados próximos a este.

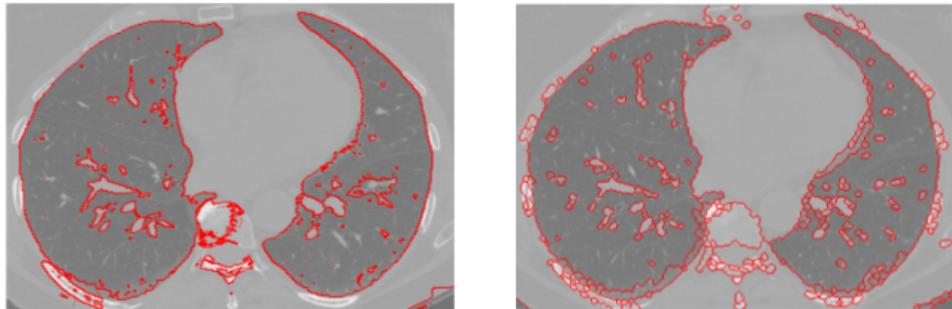
Figura 5.5 – Resultados para USE de imagens coloridas.



Os resultados após a aplicação do algoritmo *Region Merging* são apresentados na Figura 5.6. Como explicado no capítulo anterior, optou-se em aplicar esta técnica com o intuito de melhorar a qualidade da segmentação, permitindo que *superpixels* com características semelhantes e pertencentes ao mesmo objeto, sejam agrupados em regiões maiores. Não houveram testes de eficiência para os resultados da aplicação desta técnica, de forma que o objetivo desta aplicação foi apenas para efeitos visuais, para obter uma melhor qualidade nos resultados produzidos pelo ESLIC. Na

Figura 5.6, imagem da esquerda, é apresentada a imagem gerada pela técnica *5-D Spectral Clustering*, descrita no capítulo anterior. A imagem da direita apresenta o resultado gerado por uma outra técnica, conhecida como DBSCAN, descrita em (Kovesi, P., 2013). É possível observar, na imagem da esquerda, que as estruturas internas do pulmão estão melhor segmentadas nesta imagem, do que a da direita. Outro ponto a ser observado é a forma com que as técnicas de *Region Merging* agruparam os inúmeros *superpixels* em regiões maiores. Um ponto importante a ser comentado é que houve uma manipulação da imagem médica a fim de melhorar o resultado gerado pela aplicação da técnica desenvolvida de *Region Merging*. Optou-se em selecionar uma região da imagem, onde foi dado mais ênfase aos pulmões, retirando as demais informações desnecessárias da imagem. Esta seleção é conhecida em aplicações de processamento de imagens como *Bounding-Box*, e foi realizada manualmente de forma a obter uma imagem contendo poucas informações irrelevantes.

Figura 5.6 – Comparação entre os resultados do *Region Merging*.



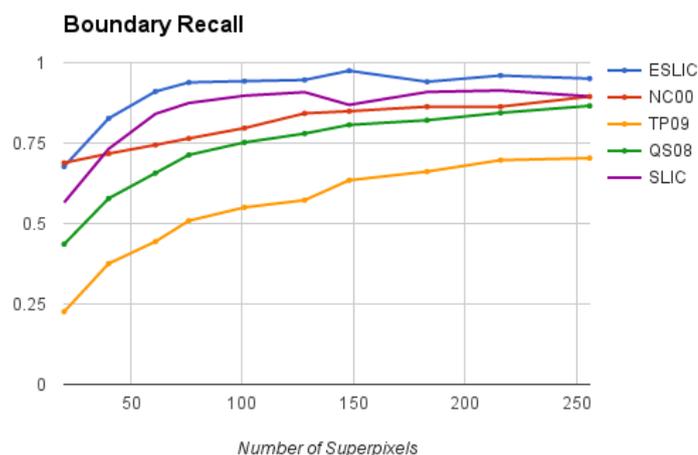
Por fim, um último teste foi realizado com a intenção de analisar o desempenho da técnica proposta contra os demais métodos de superpixels, inclusive o SLIC, utilizando-se imagens médicas providas pelo CTED. Como este banco de imagens não fornece imagens GT, percebeu-se que o resultado produzido anteriormente, pelo algoritmo *Region Merging*, poderia ser utilizado como uma imagem GT, uma vez que as principais estruturas estariam segmentadas, como o contorno dos pulmões e as estruturas internas onde existem forte indícios de nódulos cancerígenos. Este teste é útil, uma vez que pode-se comparar o método desenvolvido neste trabalho com o SLIC, em um contexto de imagens médicas. Desta forma, a partir da imagem GT apresentada na Figura 5.7, repetiu-se todos os procedimentos descritos anteriormente, utilizando-se as mesmas métricas de avaliação.

Figura 5.7 – Imagem GT.



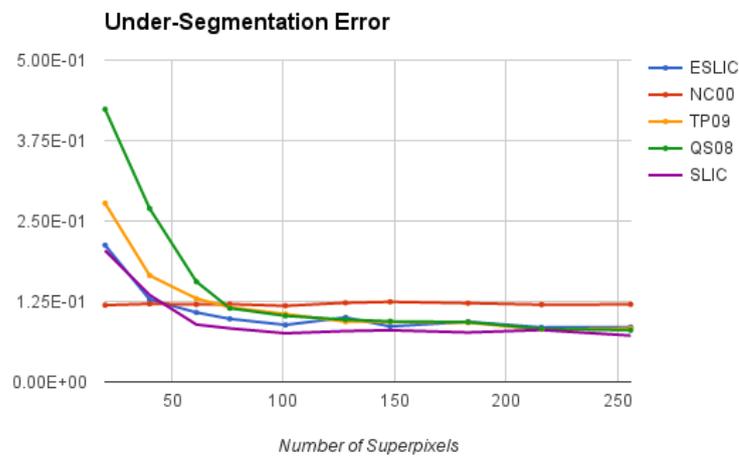
Os resultados apresentados para a métrica BR, mostrado na Figura 5.8, demonstraram que a versão ESLIC conseguiu superar os demais métodos, conforme o número de superpixels iria aumentando. Já para a métrica USE, apresentado na Figura 5.9, a técnica proposta foi pouco inferior que o SLIC, alcançando resultados próximos ao QS e TP, sendo superior a estes em alguns casos, quando considerados um número de superpixels menor que 100.

Figura 5.8 – Resultados para BR.



A Figura 5.10 apresenta um comparativo entre as imagens geradas por cada um dos métodos utilizados neste trabalho. A imagem central superior, representa uma imagem médica, provida pelo CTED, selecionada manualmente, de forma a dar uma maior ênfase à região dos pulmões, utilizando-se uma técnica conhecida como *Bouding-Box*. A partir desta imagem, gerou-se uma imagem GT, através do algoritmo

Figura 5.9 – Resultados para USE.



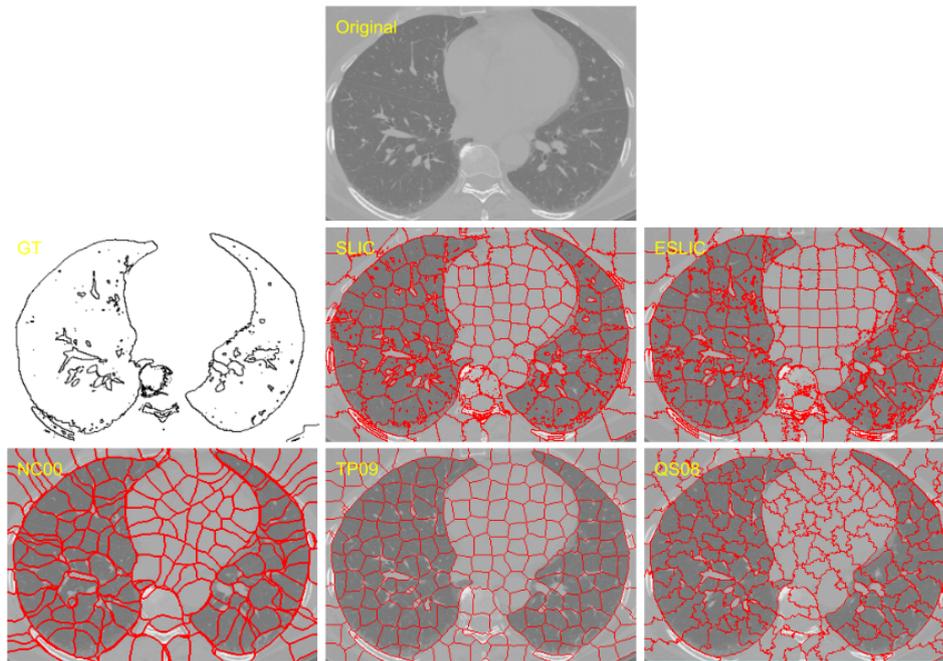
Region Merging, conforme explicado na Seção 4.4, do Capítulo 4, sendo utilizada para realizar os testes de desempenho pelas métricas BR e USE, apresentados nas Figuras 5.8 e 5.9. As demais imagens apresentadas na Figura 5.10 são resultantes da aplicação de cada um dos métodos de superpixels, escolhidos para este trabalho.

5.4 DESEMPENHO NA SEGMENTAÇÃO

Como pôde ser visto anteriormente, a técnica proposta obteve resultados significativos em relação a outros métodos, inclusive o SLIC, quando comparado com imagens coloridas. Esta seção descreve o desempenho de cada um dos métodos utilizados neste trabalho, em relação às comparações utilizando as métricas de avaliação.

- a) NC00: O método NC, obteve excelentes resultados quanto à métrica BR, tanto para imagens médicas, quanto para coloridas. Nas imagens providas pelo CTED, observou-se que à medida que aumentava o número de *superpixels*, a qualidade da segmentação também chegava próxima à da imagem *ground truth*. Apenas com 80 e 100 *superpixels*, os valores de BR para este método possuíram um pequeno grau de diferença em relação ao ESLIC. Observou-se o mesmo comportamento nas imagens coloridas. Com 20 *superpixels*, este método foi superior ao QS e TP

Figura 5.10 – Comparação com imagens médicas selecionadas com *Bounding-Box*.



e inferior ao SLIC e ESLIC. Já com 50 *superpixels*, este método só fica atrás do ESLIC. Porém, acima deste número de *superpixels*, este método passa a obter os melhores resultados. Já para as imagens médicas na métrica USE, os resultados encontrados foram pouco significativos. Apenas nos 200 *superpixels* este método obteve um bom resultado, porém alcançado também por outros dois métodos, ESLIC e TP. Com 100 *superpixels*, foi inferior apenas ao TP. Nas demais, foi inferior aos outros métodos. Para imagens coloridas, a qualidade de segmentação diminui conforme aumenta o número de *superpixels*. Até os 80 *superpixels*, este método obteve superioridade em relação aos demais, havendo, porém, uma piora nos resultados obtidos. Acima destes 80, os resultados passam a ser inferiores do que as demais versões. Para os testes realizados com a imagem *Bounding-Box*, provida pelo CTED, o método foi superior aos demais, quando considerados 20 *superpixels*, para a métrica BR. Conforme o número de *superpixels* aumenta, o método fica superior aos algoritmos QS e TP e inferior ao SLIC e ESLIC. Para a métrica USE, os resultados para esta técnica mantêm-se estáveis, sendo superior aos demais métodos para 20 e 40 *superpixels* e obtendo piores resultados a partir de 80 *superpixels*;

- b) TP09: o método TP obteve os piores resultados, tanto para imagens médicas, quanto para coloridas, na métrica BR. Em nenhum momento, os resultados alcançados por este método foram superiores ou chegaram perto de outros resultados produzidos pelas demais versões. Já para as imagens médicas, com a métrica USE, os resultados podem ser considerados bons. Com 100 *superpixels*, este método foi o que apresentou melhores resultados. Acima deste número, este método apresentou resultados superiores aos demais, porém sempre com a aproximação do ESLIC. Entretanto, este mesmo comportamento não pode ser observado no gráfico para imagens coloridas, onde verifica-se que este método foi superior apenas ao QS, quando considerados 20 *superpixels*, e superior ao NC acima de 120 *superpixels*, sendo sempre inferior às demais versões. Com 100 *superpixels*, este método acabou sendo o pior dentre todos. Para os testes com a imagem *Boundig-Box*, o método foi inferior aos demais, para qualquer número de *superpixels*, com a métrica BR. Para a métrica USE, os resultados para esta técnica são superiores ao QS até 60 *superpixels*, possuindo resultados próximos ao ESLIC e QS, conforme este número vai aumentando;
- c) QS08: o método QS apresentou o mesmo comportamento, em ambos tipos de imagem, para a métrica BR. Em ambos, ele foi superior somente ao TP, sendo inferior às demais. Já para as imagens médicas, na métrica USE, os resultados não foram os melhores. Apenas com 80 *superpixels*, esta versão foi a melhor. Após isso, ela tomou proporções inferiores às demais, apresentando, por vezes, resultados semelhantes ao NC. Com 1500 e 1800 *superpixels*, ela foi superior ao NC e inferior aos demais métodos. Já para as imagens coloridas, os resultados encontrados foram inferiores aos demais, quando considerados 20, 50 e 80 *superpixels*, nestes dois últimos com a aproximação do TP. A partir daí, este método foi superior ao NC e TP e inferior ao ESLIC e SLIC. Com 200 *superpixels*, ele somente foi inferior ao SLIC, sendo superior aos demais. Para os testes com a imagem *Boundig-Box*, o método foi inferior aos demais, para qualquer número de *superpixels*, com a métrica BR. Para a métrica USE, os resultados para esta técnica são superiores ao QS até 60 *superpixels*, possuindo resultados próximos ao ESLIC e QS, conforme este número vai aumentando;
- d) SLIC: o método SLIC somente pode ser comparado quando usadas as imagens

coloridas, fornecidas pelo (MARTIN et al., 2001). A causa disso é que, para as imagens médicas, os resultados obtidos por este método foram utilizados como imagens *ground truth*. Assim sendo, para a métrica BR, houve uma certa significância, onde pode observar-se que ele foi superior ao QS e TP e inferior ao ESLIC e NC, a partir dos 50 *superpixels*. Entretanto, para 20 *superpixels*, o resultado foi apenas inferior ao ESLIC. Já para a métrica USE, o método obteve resultados superiores, e com uma certa aproximação do ESLIC, a partir dos 120 *superpixels*. Para um número menor de *superpixels*, o método foi superior apenas ao QS e TP, sendo inferior ao ESLIC e NC. Para os testes com a imagem *Boundig-Box*, o método foi inferior aos demais, para qualquer número de *superpixels*, com a métrica BR. Para a métrica USE, os resultados para esta técnica são superiores ao QS até 60 *superpixels*, possuindo resultados próximos ao ESLIC e QS, conforme este número vai aumentando;

- e) ESLIC: O método ESLIC, desenvolvido neste trabalho, obteve bons resultados, tanto para imagens médicas como para coloridas, para a métrica BR. Para as imagens fornecidas pelo CTED, foi superior dentre todos os métodos, apenas uma vez, quando considerados 80 *superpixels*, tendo, porém, o NC na sua proximidade. Para os demais testes com números de *superpixels*, conforme iam aumentando, percebeu-se que ele foi superior apenas ao QS e TP, sendo inferior ao NC. Para imagens coloridas, o comportamento foi semelhante ao anterior. Os resultados foram superiores aos demais, com 20 e 50 *superpixels*, e terminou sendo inferior apenas ao NC, para um número de *superpixels* maior. Para a métrica USE, com as imagens médicas, o método somente foi inferior aos demais, quando considerados 80 *superpixels*, obtendo melhores resultados, acima deste número, ao lado do TP. Já para as imagens coloridas, o método teve os melhores resultados com 100, 120 e 150 *superpixels*, tendo, nas proximidades, o SLIC. Quando considerados 20 *superpixels*, ele foi inferior ao NC, possuindo um pequeno grau de inferioridade ao SLIC também. Com 50 e 80 *superpixels*, ele ficou próximo ao NC, que até então estava com as melhores qualidades de segmentação. Com 200 *superpixels*, porém, foi superado pelo SLIC e QS. Para os testes com a imagem *Boundig-Box*, o método foi inferior aos demais, para qualquer número de *superpixels*, com a métrica BR. Para a métrica USE, os resultados para esta técnica são superiores ao

QS até 60 *superpixels*, possuindo resultados próximos ao ESLIC e QS, conforme este número vai aumentando.

6 CONCLUSÃO

Embora a técnica de segmentação proposta, baseada no SLIC alcance resultados significativos quando comparados somente com alguns métodos publicados na bibliografia, a metodologia proposta ainda possui algumas etapas para uma melhor qualidade de segmentação. Os algoritmos NC, QS, TP e SLIC foram comparados contra o ESLIC utilizando-se as métricas BR e USE. Os resultados mostraram que o algoritmo proposto é superior, na métrica USE, do que as demais versões. Quando considerou-se BR, ESLIC produziu melhores resultados do que QS e TP, mas acabou sendo inferior à NC. Apesar das comparações qualitativas e quantitativas, realizada sem que houvessem imagens *ground truth* a partir das fatias de TC do CTED e seus metadados correspondentes, não há nenhuma razão para acreditar que eles não são confiáveis.

Além dos testes realizados com imagens do CTED, as comparações também foram feitas em imagens coloridas fornecidas pelo banco (MARTIN et al., 2001). Estes testes foram realizados com o intuito de observar o comportamento dos resultados apresentados pelo ESLIC, quando comparados com as demais versões, e verificar se estes resultados mantêm o mesmo desempenho mostrado para imagens médicas. A principal vantagem da utilização deste banco de imagens coloridas, é seu fornecimento de imagens segmentadas *ground truth*, o que poderia dar uma maior exatidão além de aumentar o nível de confiança na técnica desenvolvida. Uma outra vantagem é que o ESIC poderia ser comparado também com sua versão original, SLIC, comparação que não pode ser observada nos testes com as imagens providas pelo CTED. Os testes encontrados, para a métrica BR, mostraram um comportamento semelhante ao encontrado para as imagens do CTED, com uma superioridade do ESLIC sobre o TP, QS e SLIC, sendo inferior apenas ao NC, conforme o número de *superpixels* aumenta. Já para a métrica USE, embora o gráfico apresente-se com uma forma desfigurada em relação ao gráfico apresentado para imagens médicas, os resultados para o ESLIC conseguiram ser superiores que as demais versões, quando considerados 100, 120 e 150 *superpixels*, o que demonstra que a qualidade de segmentação gerada pelo método proposto atingiu seu objetivo.

Verificou-se, também, que muitos *superpixels*, gerados pela segmentação, possuem características semelhantes, além de fazerem parte do mesmo objeto. Assim sendo, uma nova etapa de segmentação foi aplicada sobre os *superpixels*, permitindo uma melhor qualidade na imagem segmentada.

REFERÊNCIAS BIBLIOGRÁFICAS

ACHANTA, R. e. a. Slic superpixels. **Technical report, École Polytechnique Fédérale de Lausanne**, 2010.

_____. Slic superpixels compared to state-of-the-art superpixel methods. **Transactions on Pattern Analysis and Machine Intelligence**, v. 34, 2012.

BEGA, G. e. a. Three-dimensional ultrasonographic imaging in obstetrics. **J Ultrasound Med.**, 2001.

BERGH, M. a. Seeds: Superpixels extracted via energy-driven sampling. **European Conference on Computer Vision**, 2012.

Birodkar, V. **A Simple Programmer's Blog**. 2014. Acesso em 20 fev. 2015. Disponível em: <<https://vcansimplify.wordpress.com/2014/07/29/normalized-cuts-on-region-adjacency-graphs/>>.

BOROVEC, J.; KYBIC, J. jslic: superpixels in imagej. **Computer Vision Winter Workshop**, 2014.

BRONSON, J. G. Ultrasound in women's health: The view in 2002. **Medical Imaging**, 2002.

BROWN, M. S. e. a. Method for segmenting chest ct image data using an anatomical model: Preliminary results. **IEEE Transactions on Medical Imaging**, 1997.

BUZUG, T. M. **Computed Tomography: From Photon Statistics to Modern Cone-Beam CT**. [S.l.]: Springer, 2008. ISBN 978-3-540-39408-2.

COMANICIU, D.; MEER, P. Mean shift: A robust approach toward feature space analysis. **IEEE Trans. Pattern Anal. Machine Intell.**, 2002.

DAINTY, J. C.; SHAW, R. Image science. **Academic Press**, 1976.

ERONDU, O. F. **Medical Imaging**. [S.l.]: InTech, 2011. ISBN 978-953-307-774-1.

FELZENSZWALB, P.; HUTTENLOCHER, D. Efficient graph-based image segmentation. **International Journal of Computer Vision**, 2004.

Fulkerson, B. and Vedaldi, A. **Quick shift image segmentation**. 2007. Acesso em 20 fev. 2015. Disponível em: <<http://www.vlfeat.org/api/quickshift.html>>.

HOLZER, M.; DONNER, R. Over-segmentation of 3d medical image volumes based on monogenic cues. **Proceedings of the CVWW**, 2014.

HSU, C. Y.; DING, J. J. Efficient image segmentation algorithm using slic superpixels and boundary-focused region merging. **International Conference on Information, Communications and Signal Processing**, 2013.

JONES, J. L.; XIE, X.; ESSA, E. Combining region-based and imprecise boundary-based cues for interactive medical image segmentation. **Int J Numer Method Biomed Eng**, v. 12, 2014.

Kovesi, P. **Image Segmentation using SLIC SuperPixels and DBSCAN Clustering**. 2013. Acesso em 23 fev. 2015. Disponível em: <<http://www.peterkovesi.com/projects/segmentation/>>.

LEVINSHTEIN, A. et al. Turbopixels: Fast superpixels using geometric flows. **Transactions on Pattern Analysis and Machine Intelligence**, 2009.

MAINTZ, J. B. A.; VIERGEVER. A survey of medical image registration. **Medical Image Analysis**, 1998.

MANSOOR, A.; BAGCI, U.; MOLLURA, D. Near-optimal keypoint sampling for fast pathological lung segmentation. **IEEEEMBC**, 2014.

MARTIN, D. et al. A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics. **IEEE International Conference on Computer Vision**, 2001.

MOORE, A. e. a. Superpixel lattices. **IEEE CComputer Vision and Pattern Recognition**, 2008.

MURTHY, S. Retrospective validation of medical device software. **Medical Device and Diagnostic Industry**, 1995.

Neubert, P. and Protzel, P. **Superpixel Benchmark and Comparison**. 2015. Acesso em 25 fev. 2016. Disponível em: <<https://www.tu-chemnitz.de/etit/proaut/forschung/cv/segmentation.html.en>>.

PRASAD, M. N. e. a. Automatic segmentation of lung parenchyma in the presence of diseases based on curvature of ribs. **Academic Radiology**, 2008.

PU, J. e. a. Adaptive border marching algorithm: Automatic lung segmentation on chest ct images. **Computerized Medical Imaging and Graphics**, v. 32, 2008.

REKIK, A. et al. Medical image analysis methods in mr/ct-imaged acute-subacute ischemic stroke lesion: Segmentation, prediction and insights into dynamic evolution simulation models. a critical appraisal. **NeuroImage: Clinical**, v. 1, 2012. ISSN 2213-1582.

REN, C. Y.; REID, I. gslc: a real-time implementation of slic superpixel segmentation. **Technical report**, 2011.

RIKXOORT, E. M. e. a. Automatic lung segmentation from thoracic computed tomography scans using a hybrid approach with error detection. **Medical Physics**, 2009.

ROCKALL, A. et al. **Diagnostic Imaging**. [S.l.]: Wiley-Blackwell, 2013. ISBN 978-1-118-52424-4.

RODRIGUEZ-GONZÁLEZ, A. e. a. Using experts feedback in clinical case resolution and arbitration as accuracy diagnosis methodology. **Comput Biol Med**, v. 43, 2013.

SHEIKH, Y. A.; KHAN, E. A.; KANADE, T. Mode-seeking by medoidshifts. **CVPR**, 2007.

SHI, J.; MALIK, J. Normalized cuts and image segmentation. **IEEE Transactions on Pattern Analysis and Machine Intelligence (PAMI)**, 2000.

Siemens. **Medical Imaging**. 2016. Acesso em 06 mar. 2016. Disponível em: <<http://www.healthcare.siemens.com/medical-imaging>>.

SLUIMER, I. et al. Computer analysis of computed tomography scans of the lung: A survey. **IEEE Transactions on Medical Imaging**, 2006.

SMITH, N. B.; WEBB, A. **Introduction to Medical Imaging - Physics, Engineering and Clinical Applications**. [S.l.]: Cambridge University Press, 2010. ISBN 9780521190657.

SORENSEN, L.; SHAKER, S.; BRUIJNE. Quantitative analysis of pulmonary emphysema using local binary patterns. **IEEE Transactions on Medical Imaging**, 2010.

SUETENS, P. **Fundamentals of Medical Imaging**. [S.l.]: Cambridge University Press, 2009. ISBN 9780511596803.

TANG, D.; FU, H.; CAO, X. Topology preserved regular superpixel. **International Conference on Multimedia and Expo**, 2012.

TORRES, A. S. A. **Segmentação de Imagens Médicas Visando a Construção de Modelos Médicos**. 2012. 83 p. Dissertação (Mestrado em Tecnologia Biomédica) — Instituto Politécnico de Bragança - Escola Superior de Tecnologia e Gestão, 2012.

VEDALDI, A.; SOATTO, S. Quick shift and kernel methods for mode seeking. **ECCV**, 2008.

VINCENT, L.; SOILLE, P. Watersheds in digital spaces: An efficient algorithm based on immersion simulations. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, 1991.

WILKS, R. J. **Principles of Radiological Physics**. [S.l.]: Churchill Livingstone, 1987. ISBN 978-0443037801.

ZHOU, S.; CHENG, Y.; TAMURA, S. Automated lung segmentation and smoothing techniques for inclusion of juxtapleural nodules and pulmonary vessels on chest ct images. **Biomedical Signal Processing and Control**, v. 13, 2014.