



INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO CEARÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA DE TELECOMUNICAÇÕES
CAMPUS DE FORTALEZA

Elizângela de Souza Rebouças

**MÉTODO DE LEVEL SET BASEADO NA ESTIMAÇÃO DE PARZEN PARA
SEGMENTAÇÃO DE AVC EM IMAGENS DE TOMOGRAFIA
COMPUTADORIZADA**

Fortaleza - Ceará

2017

Elizângela de Souza Rebouças

**MÉTODO DE LEVEL SET BASEADO NA
ESTIMAÇÃO DE PARZEN PARA SEGMENTAÇÃO DE
AVC EM IMAGENS DE TOMOGRAFIA
COMPUTADORIZADA**

Dissertação submetida à Coordenação do Programa de Pós-Graduação em Engenharia de Telecomunicações do Instituto Federal do Ceará, como requisito parcial para obtenção do grau de Mestre em Engenharia de Telecomunicações.

Área de concentração: Sistemas de Telecomunicações.

Orientador: Prof. Dr. Regis Cristiano Pinheiro Marques.

Fortaleza
2017

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

R292m Rebouças, Elizângela de Souza.

MÉTODO DE LEVEL SET BASEADO NA ESTIMAÇÃO DE PARZEN PARA SEGMENTAÇÃO DE AVC EM IMAGENS DE TOMOGRAFIA COMPUTADORIZADA / Elizângela de Souza Rebouças. 2017. 85 f. : il. color.

Dissertação (Mestrado Acadêmico) Instituto Federal do Ceará, Mestrado em Engenharia de Telecomunicações, Campus Fortaleza, 2017.

Orientação: Prof. Dr. Regis Cristiano Pinheiro Marques.

1. Imagem Médica. 2. AVC. 3. janela de parzen. 4. level set. I. Título.

CDD 621.382



INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO CEARÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE TELECOMUNICAÇÕES

Elizângela de Souza Rebouças

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

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

Prof. Dra. Fátima N. Sombra de Medeiros
Universidade Federal do Ceará (UFC)

Prof. Dr. Ajalmar Rêgo da Rocha Neto
Instituto Federal do Ceará (IFCE)

Prof. Dr. Francisco José Alves de Aquino
Instituto Federal do Ceará (IFCE)

Fortaleza, 13 de Janeiro de 2017

Dedico este trabalho à minha família.

Agradecimentos

Agradeço primeiramente a Deus pela oportunidade de viver.

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

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

Ao meu orientador Prof. Dr. Regis Cristiano Pinheiro Marques por sua orientação, atenção, paciência e por todo o aprendizado que recebi ao longo do mestrado.

Aos meus irmãos, Wellington e Edilândia, pelos momentos de brincadeiras, conversas soltas e por sempre me incentivarem nos momentos mais difíceis da minha vida acadêmica.

Aos meus colegas do mestrado, que ao longo do tempo se tornaram amigos, pela ajuda e estímulo ao longo desta caminhada. Esses dois anos de aprendizado e sacrifícios não seriam tão divertidos sem a companhia deles, Shara, Alan, Saulo, Madson, Clifte e Lucas.

Ao Laboratório de Processamento Digital de Sinais.

A FUNCAP pelo apoio financeiro.

Ao Instituto Federal de Educação, Ciência e Tecnologia do Ceará e a todo o corpo docente do Programa de Pós-Graduação em Engenharia de Telecomunicações pelo ensino de qualidade que recebi.

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

“If you can dream it, you can do it.”

Walt Disney

Resumo

As doenças não transmissíveis, como doenças cardiovasculares, câncer, diabetes e doenças pulmonares crônicas são as principais causas de morte no mundo, e entre elas, as doenças cardiovasculares são a causa número 1 de morte. O Acidente Vascular Cerebral (AVC) é a segunda causa de morte mais frequente e uma das principais causas de incapacidade nos países industrializados. Dos 17,5 milhões de mortes causadas por doenças cardiovasculares em 2012, estima-se que 6,7 milhões foram causadas por AVC. No Brasil, o AVC mata cerca de 87 mil pessoas por ano. Neste trabalho, o foco de estudo é o Acidente Vascular Cerebral do tipo hemorrágico, que é responsável por 40% de todas as mortes por AVC. Em serviços clínicos e na pesquisa científica, o AVC não tem tanta prioridade quando comparada a outras doenças com impacto semelhante ou reduzido sobre a saúde pública. Para detectar e analisar esta doença é muito comum o uso de imagens do crânio, notadamente a Tomografia Computadorizada (TC) e a Imageamento por Ressonância Magnética (IRM). A TC é preferível em relação à IRM devido a maior disponibilidade, menor custo, maior rapidez, além de ser menos afetada por ruídos. Este exame possibilita detectar e avaliar a severidade do AVC. Este trabalho propõe uma nova abordagem para segmentar o AVC utilizando imagens de TC do crânio, tendo como objetivo o auxílio ao diagnóstico médico. Esta abordagem propõe iniciar de forma automática o método *level set* dentro da região de AVC e utilizar uma abordagem de estimação não paramétrica baseada na Janela de Parzen para segmentação deste AVC. Os resultados obtidos pela abordagem proposta são comparados com os resultados dos algoritmos de *level set* utilizando *fuzzy C-means*, *level set* com base no método de propagação coerente, *fuzzy C-means*, Watershed e Crescimento de Região, que são comumente utilizados neste campo. Esta avaliação têm como base de validação a segmentação obtida por um médico especialista. Os resultados experimentais mostram que o método proposto apresenta um desempenho superior aos demais avaliados, apresentando-se como uma ferramenta promissora no auxílio ao diagnóstico médico.

Palavras-Chave: *Imagem Médica, AVC, janela de parzen, level set.*

Abstract

Noncommunicable diseases as cardiovascular diseases, cancer, diabetes and chronic lung diseases are the major causes of death worldwide, and among them cardiovascular diseases the number 1 cause of death throughout the world. Cerebrovascular Accident (CVA), also known as stroke, is the second most frequent cause of death and one of the main causes of disability in industrialised countries. The World Health Organization (WHO) estimated that 17.5 million people died from cardiovascular diseases in 2012 and 38% of these died from stroke. In Brazil, stroke kills 87 thousand annually. There are two types of stroke, the ischaemic and the intracerebral hemorrhage. In this work, we focused on intracerebral hemorrhage which comprehends 40% of all strokes deaths. Compared with other diseases with similar or reduced impact on public health stroke has been allocated a lower priority in clinical services and research. In order to detect and analyze this disease, it is very common to use skull images, mainly Computed Tomography (CT) and Magnetic Resonance Imaging (MRI). CT is more appropriate than MRI it is highly available, low cost, faster, and less affected by noise. This examination makes it possible to detect and evaluate a stroke severity. Aiming to assist medical diagnoses through CT scans, this work proposes a new approach to segment CT images of a skull damaged by stroke. The results of the proposed approach are compared against those fuzzy-based level set method, the level set algorithm based on the coherent propagation method, Fuzzy C-Mean, and also those from the Watershed and Region Growing algorithms, which are commonly used in this field. The approach was validated by comparing its results with segmentation obtained by a medical specialist. The experimental results show that the proposed method over performed the others evaluated ones, and that it is a promising tool to assist medical diagnoses.

Keywords: *Medical Imaging, stroke, Parzen-window, level set.*

Conteúdo

Lista de Figuras

Lista de Tabelas

Lista de Símbolos

Lista de Abreviações

1	Introdução	20
1.1	Estado da arte	22
1.2	Motivação	24
1.3	Objetivos	26
1.3.1	Objetivo Geral	26
1.3.2	Objetivos Específicos	26
1.4	Contribuições e Produção Científica	27
1.5	Organização da Dissertação	28
2	Estado da Arte	29
2.1	Acidente Vascular Cerebral	29
2.2	Métodos de Segmentação	32
2.2.1	Método Crescimento de Região	32
2.2.2	Método Watershed	33
2.2.3	Algoritmo de Agrupamento <i>Fuzzy C-means</i> (FCM)	35
2.2.4	<i>Level Set</i>	36

2.2.4.1	Algoritmo de <i>Level set</i> com Fuzzy C-means ($LSFCM_{evol}$)	38
2.2.4.2	Algoritmo de <i>Level Set</i> com base no Método de Propagação Coerente (LSCPM)	40
2.2.4.3	Algoritmo rápido de <i>Level Set</i>	41
2.3	Janela de Parzen	42
2.4	Conclusão do capítulo	43
3	Metodologia Proposta	44
3.1	Análise das Densidades Radiológicas do Crânio	46
3.2	Algoritmo Parzen <i>level set</i>	49
3.3	Conclusão do capítulo	52
4	Métricas Utilizadas para Avaliação dos Resultados de Segmentação	53
4.1	Acurácia	54
4.2	Precisão, Sensitividade e Especificidade	55
4.3	Coefficiente de Correlação de Matthew	55
4.4	Índice Jaccard	56
4.5	Coefficiente Dice	56
4.6	Conclusão do capítulo	56
5	Experimentos e Resultados	58
5.1	Aquisição de imagens	58
5.2	Análise do algoritmo de iniciação	59
5.3	Análise dos métodos de segmentação de AVCh em imagens de TC do crânio	60
5.4	Conclusão do capítulo	71
6	Conclusão e Trabalhos Futuros	72
	Referências	74

Lista de Figuras

1	Exemplos de cortes axial, coronal e sagital, bem como a resrepresentação do modelo em três dimensões (3D) (FREITAS, 2013).	21
2	Diferenciação dos tipos de AVC (AMERICAN HEART ASSOCIATION AND AMERICAN STROKE ASSOCIATION, 2016).	30
3	Faixas da escala de atenuação em Unidades Hounsfield (FREITAS, 2013). . . .	31
4	Exemplo de segmentação de um objeto utilizando o método Crescimento de Região: 1) Imagem de entrada; 2) Informações dos tons de cinza da imagem de entrada; 3) Escolha do <i>pixel</i> semente; 4)-9) Processo de agregação de <i>pixels</i> vizinhos a região de interesse; 10) Objeto segmentado e 11) Imagem de saída. .	33
5	Exemplo de segmentação obtida pelo método Watershed: 1) imagem original; 2) vista topográfica; 3) a 4) duas fases da inundação; 5) resultado de novas inundações; 6) começo da fusão da água de duas bacias hidrográficas (uma pequena barragem foi construída entre elas); 7) barragens maiores; e 8) linhas finais segmentação (GONZALEZ; WOODS, 2010).	34
6	Propagação de uma curva fechada $\vec{\phi}$ submetida a um campo de velocidades $(\pm F\vec{\eta})$ (BRAGA, 2016).	37
7	Representação da função de <i>level set</i> $\psi(\mathbf{x},t)$ e da curva $\vec{\phi}(s,t)$ Sethian (1999). .	37
8	Possíveis estados iniciais da superfície ou <i>level set</i> zero: a) com apenas um elemento; e b) com múltiplos elementos.	38
9	Fluxograma de execução do método LSDRC _{parzen}	45
10	Processo de segmentação do crânio: a) imagem original; b) imagem original limiarizada; c) seleção do objeto de maior área; e f) região do cérebro.	46

11	Da esquerda para direita, três exemplos da etapa de iniciação em que o <i>level set</i> zero é determinado pela análise das densidades radiológicas cerebral: a) crânio segmentado; b) análise das densidades UH do crânio (fluido espinhal em magenta, massa branca em verde, massa cinzenta em azul, sangue em vermelho); e c) <i>pixels</i> que seguem a regra $P_0 < 0,5$ destacados em vermelho dentro do crânio.	48
12	Exemplo da estimação da FDP da Janela de Parzen: a) região do crânio; b) estimação da distribuição de probabilidade espacial.	49
13	Segmentação obtida pela abordagem proposta com a iniciação baseada na análise das densidades radiológicas do cérebro: a) iniciação contorno ativo; b) - e) evolução do processo de segmentação; e f) resultado final da segmentação.	51
14	Regiões onde VP , FP , VN e FN são computadas. O círculo ROI representa a região de referência (padrão ouro). O círculo RS representa a região segmentada por um método computacional (Adaptado de Garcia, Dominguez e Mederos (2015)).	54
15	Resultados da iniciação da abordagem proposta em comparação com o método <i>Fuzzy C-means</i> . a) imagem original; b) iniciação da abordagem proposta; c) iniciação utilizando <i>Fuzzy C-means</i>	59
16	Exemplos de segmentação do AVCh em imagens de TC do crânio obtidos por métodos de iniciação manual, sendo: a) em branco, padrão ouro obtido pelo médico especialista; b) em azul, método LSCPM; c) em rosa, método FCM; d) em verde, método WS e e) em amarelo, método CR.	61
17	Exemplos de segmentação de AVCh obtidos por métodos de segmentação automática em imagens de TC do crânio, sendo: a) em branco, padrão ouro obtido por médico especialista; b) em vermelho, abordagem proposta, $LSDRC_{parzen}$; c) em ciano, método $LSDRC_{evol}$; d) em magenta, método $LSFCM_{parzen}$; e e) em laranja, método $LSFCM_{evol}$	62
18	Boxplot do desempenho dos métodos de segmentação do AVCh em imagens de TC do crânio utilizando as métricas Coeficiente de Correlação de Matthew (MCC), Índice Jaccard e DICE. A abordagem proposta neste trabalho é apresentada em vermelho.	65

19	As regiões de segmentação do AVC obtidas pelos métodos em comparação, adotando o verde para os verdadeiros positivos, o vermelho para o falso positivo e o azul para o falso negativo: a) Imagem Original; b) LSDRC _{parzen} ; c) LSFCM _{parzen} ; d) LSDRC _{evol} ; e) LSFCM _{evol} ; f) LSCPM; g) FCM; h) WS; i) CR.	66
20	Diferença entre a segmentação do especialista e os métodos avaliados. a) Imagem Original; b) LSDRC _{parzen} ; c) LSFCM _{parzen} ; d) LSDRC _{evol} ; e) LSFCM _{evol} ; f) LSCPM; g) FCM; h) WS; i) CR.	68
21	Resultados dos métodos de segmentação em imagens que contém áreas pequenas de AVCh. a) Imagem Original; b) LSDRC _{parzen} ; c) LSFCM _{parzen} ; d) LSDRC _{evol} ; e) LSFCM _{evol} ; f) LSCPM; g) FCM; h) WS; i) CR.	69
22	Gráfico de tempo dos métodos avaliados na segmentação do AVCh em imagens de TC do crânio: a) tempo de 0-40s e b) tempo de 0-8s.	70

Lista de Tabelas

1	Representação do modelo de matriz de confusão 2x2 utilizada.	54
2	Avaliação da segmentação do AVC hemorrágico através dos métodos CR, WS, LSCPM, FCM, LSDRC _{parzen} , LSFCM _{parzen} , LSDRC _{evol} e LSFCM _{evol} pelas métricas acurácia (ACC), Precisão (PRE), Sensitividade (SEN) e Especificidade (SPC).	63
3	Avaliação da segmentação do AVC hemorrágico através dos métodos CR, WS, LSCPM, FCM, LSDRC _{parzen} , LSFCM _{parzen} , LSDRC _{evol} e LSFCM _{evol} pelas métricas Coeficiente de Correlação de Matthew (MCC), Índice Jaccard (Jac) e Dice.	63
4	Tempos de segmentação do AVC hemorrágico pelos métodos LSDRC _{parzen} , LSFCM _{parzen} , LSDRC _{evol} , LSFCM _{evol} , CR, WS, LSCPM e FCM.	67

Lista de Símbolos

J	função <i>Fuzzy C-means</i> padrão
z	<i>pixel</i> de uma imagem
c	<i>pixel</i> central de uma região
u	função de pertinência FCM
m	parâmetro de controle <i>fuzzy</i>
$\vec{\phi}(s,t)$	curva fechada de evolução do <i>level set</i>
$\vec{\eta}$	vetor normal à frente $\vec{\phi}(s,t)$
$\psi^k(\mathbf{x})$	função de <i>level set</i>
s	coordenadas da frente $\vec{\phi}$
$\mathbf{x}$	coordenadas da superfície ψ
$\psi^0(\mathbf{x})$	superfície inicial ou <i>level set</i> zero
k	iteração da evolução do <i>level set</i>
Ω_1	região interna à curva $\vec{\phi}(s,t)$
Ω_2	região externa à curva $\vec{\phi}(s,t)$
F_{prop}	velocidade de propagação
F_1, F_2	componentes da velocidade de propagação
ε	constante de normalização
$\mathcal{K}$	curvatura de ψ^k
∇	operador gradiente espacial
δ	função Dirac

λ_1, λ_2	coeficientes de ponderação da função de propagação
e_1, e_2	funções de energia interna e externa à curva
C_{Area}	área do contorno
$C_{comprimento}$	comprimento do contorno
H	função Heaviside
Δt	passo de tempo
ν	coeficiente de ponderação da suavização da curva
d	densidade de tecido humano
P	percentual de d
r	raio da função de <i>level set</i> inicial
R	hipercubo
h	tamanho da aresta do hipercubo
n	quantidade de <i>pixels</i> em uma janela $h \times h$
p	função densidade de probabilidade
φ	kernel Gaussiano
d	número de componentes de um vetor
Λ	matriz de covariância
$ \Lambda $	determinante de Λ
σ	desvio padrão
σ^2	variância
Z_1, Z_2	conjuntos de <i>pixels</i> pertencentes a região interna e externa à curva
I	intensidade de um <i>pixel</i>
μ	média
$\psi_{\bar{r}}$	superfície não regularizada

E	elemento estruturante
$\oplus$	operação morfológica de dilatação
$\ominus$	operação morfológica de erosão
MedFilt₄	filtragem mediana

Lista de Abreviações

PDI	Processamento Digital de Imagem
TC	Tomografia Computadorizada
IRM	Imagem por Ressonância Magnética
RMP	Reconstrução Multiplanar
SVH	Sistema Visual Humano
AVC	Acidente Vascular Cerebral
APSF	Adaptive Partial Smoothing Filter (Filtro de Suavização Parcial Adaptativo)
RNA	Rede Neural Artificial
CAROI	Circular Adaptive Region of Interest (Região Adaptiva Circular de Interesse)
CLAHE	Contrast Limited Adaptive Histogram Equalization (Equalização de Histograma Adaptativo de Contraste Limitado)
OMS	Organização Mundial de Saúde
RMC	Ressonância Magnética Cardíaca
LSDRC_{parzen}	<i>Level set</i> baseado nas densidades radiológicas do cérebro combinado com a Janela de Parzen
AVCh	Acidente Vascular Cerebral Hemorrágico
AVCi	Acidente Vascular Cerebral Isquêmico
UH	Unidade Hounsfield
CPTP	Condições-Padrão de Temperatura e Pressão

RMC	Ressonância Magnética Cardíaca
CR	Crescimento de Região
WS	Watershed
FCM	<i>Fuzzy C-means</i>
LSFCM_{evol}	evolução do <i>level set</i> baseado no algoritmo <i>Fuzzy C-means</i>
LSCPM	Algoritmo de <i>Level Set</i> com base no Método de Propagação Coerente
ROI	Região de Interesse
RF	Região de Fundo
RS	Região Segmentada
VP	Verdadeiro Positivo
FP	Falso Positivo
VN	Verdadeiro Negativo
FN	Falso Negativo
ACC	Acurácia
PRE	Precisão
SEN	Sensitividade
SPC	Especificidade
MCC	Matthew correlation coefficient (Coeficiente de Correlação de Matthew)
Jac	Jaccard
FDP	Função Densidade de Probabilidade
ADP	Análise das Densidades Pulmonares
ADH	Análise das Densidades dos Tecidos Humanos
DICOM	Digital Imaging and Communications in Medicine

LSDRC_{evol}

evolução do *level set* baseado nas densidades radiológicas do crânio

LSFCM_{parzen}

Level set utilizando *Fuzzy C-means* combinado com a Janela de Parzen

INTRODUÇÃO

Segmentação de imagens é uma das mais importantes e fundamentais ferramentas no Processamento Digital de Imagens (PDI). Trabalhos que se baseiam na segmentação de imagens têm sido amplamente aplicados em diversas áreas do conhecimento, tais como sistemas de sensoriamento remoto (MARQUES; MEDEIROS; NOBRE, 2012; NOBRE *et al.*, 2016), estudos forenses (TIWARI; GUPTA, 2015; SANKARAN *et al.*, 2017), análise de materiais (ALBUQUERQUE *et al.*, 2010; MOREIRA *et al.*, 2016), agricultura e meio ambiente (OLIVEIRA *et al.*, 2016; BARBEDO; KOENIGKAN; SANTOS, 2016), entre outros. Assim como em outras áreas, a segmentação de objetos em imagens na área da saúde tem sido utilizada como ferramenta alternativa ao auxílio ao diagnóstico médico nos diversos campos da Medicina (NJEH; AYED; HAMIDA, 2012; HUANG *et al.*, 2013; WANG *et al.*, 2014).

Dentre os exames existentes que permitem o auxílio ao diagnóstico médico e técnicas de processamento de imagens ressalta-se a Tomografia Computadorizada (TC) e o Imageamento por Ressonância Magnética (IRM). Esses exames têm auxiliado os médicos no diagnóstico de várias doenças, podendo-se destacar a segmentação de tumores cerebrais (SHARMA; MEGHRAJANI, 2014; PADMA; SUKANESH, 2014; MENZE *et al.*, 2015), doenças pulmonares (Rebouças Filho; CORTEZ; HOLANDA, 2011; Rebouças Filho *et al.*, 2013; RAMALHO *et al.*, 2014), cardíacas (JAARSMA *et al.*, 2012; KLEIN *et al.*, 2013), ósseas (MOL; BALASUNDARAM, 2008; LOW *et al.*, 2014), dentre outras. Em geral, a TC é preferível em relação ao IRM devido a maior disponibilidade, menor custo, maior rapidez, além de ser menos afetada por ruídos (GILLEBERT; HUMPHREYS; MANTINI, 2014).

A Tomografia Computadorizada foi desenvolvida pelo engenheiro eletricista Godfrey N. Hounsfield e o físico Allan M. Comark em 1972. Os dois cientistas foram consagrados com o Prêmio Nobel de Medicina em 1979 (HOLMES; FORREST-HAY; MISRA, 2008) por provarem que modelos matemáticos auxiliariam na produção de imagens com suficientes detalhes para análise do corpo humano. Isto é possível quantificando um feixe de raio-X transmitido através do corpo humano e obtendo informações sobre os componentes dos tecidos, criando-se assim a imagem de TC (HOUNSFIELD, 1973).

O tomógrafo, equipamento utilizado para realizar a TC, é capaz de reproduzir secções do corpo humano em frações de segundos, permitindo que o médico possa realizar a detecção, bem como o acompanhamento de diversas doenças (FREITAS, 2013; WEBB; BRANT; MAJOR, 2014). Em uma imagem de TC são considerados os cortes axiais, sagitais e coronais, a partir dos quais se faz a reconstrução do volume total escaneado, conhecido como Reconstrução Multiplanar (RMP), o que contribui para a visualização das estruturas de forma tridimensional (3D), como ilustra a Figura 1.




Figura 1: Exemplos de cortes axial, coronal e sagital, bem como a representação do modelo em três dimensões (3D) (FREITAS, 2013).

Atualmente a TC é um dos mais importantes métodos de diagnóstico, pois possibilita a aquisição de imagens em cortes, sem sobreposição, com melhor contraste entre os tecidos do que a radiografia digital e, por consequência, permitir a observação da topografia total da área de interesse (WEBB; BRANT; MAJOR, 2014). Usar imagens de TC em conjunto com técnicas de PDI é muito comum em diversos estudos e tecnologias recentes, principalmente para reduzir o tempo de análise dos exames, para aumentar a acurácia no diagnóstico ou mesmo para auxiliar o médico especialista em suas interpretações (LUIZ *et al.*, 2014).

As imagens obtidas por TC são utilizadas em sistemas de auxílio ao diagnóstico médico, o qual é definido por Marques (2001) como sendo um diagnóstico feito por um médico radiologista que utiliza o resultado da análise computacional dessas imagens médicas para validar o diagnóstico final.

Certas características de uma imagem médica podem ser utilizadas para evidenciar diferenças e similaridades entre os objetos que a compõem. O médico especialista realiza uma segmentação visual nos exames de TC para tentar distinguir determinadas áreas que possam apresentar qualquer alteração patológica, contudo, as alterações que aparecem nas imagens da TC são sutis e, em alguns casos imperceptíveis a uma simples análise visual (MESSAY; HARDIE; ROGERS, 2010). As imagens de TC apresentam informações que o olho humano não é capaz de perceber. Essas imagens digitais costumam possuir aproximadamente 4000 tons de cinza diferentes e o Sistema Visual Humano (SVH) consegue distinguir apenas aproximadamente 64 tons de cinza para uma mesma condição de luminosidade. Deste modo, uma análise matemática ou computacional pode revelar um grande número de atributos que podem não ser facilmente captados por um observador humano.

Considerando a quantidade de informações que uma imagem de TC e os benefícios de sua utilização para o diagnóstico/prognóstico médico, diversas pesquisas têm sido realizadas com o intuito de desenvolver ferramentas que auxiliem no processo de extração e análise de informações contidas na imagem. Neste sentido, o presente trabalho centraliza seus esforços na etapa de segmentação de regiões com Acidente Vascular Cerebral, especificamente do tipo hemorrágico, visando o auxílio ao diagnóstico e acompanhamento médico.

1.1 Estado da arte

Técnicas não invasivas de imagens radiológicas (TC, IRM, imagens de medicina nuclear, radiologia geral) estão presentes na prática clínica atual, reduzindo a subjetividade e tornando o diagnóstico final mais preciso. Na prática médica, uma modalidade de imagem ideal deve apresentar uma melhor resolução espacial e de contraste, ser de baixo custo, ser portátil, livre de risco, não ser invasiva e ter a capacidade de descrever as funções anatômicas e fisiológicas. Porém nenhuma modalidade satisfaz esses critérios, por isso existem várias modalidades e cada uma se adapta melhor a cada objetivo.

Na detecção e acompanhamento de AVC, a TC distingue-se como o método mais eficaz para avaliação do paciente (ADAMS *et al.*, 2005), pois permite uma análise preliminar e fornece uma maneira rápida de excluir condições que podem simular um AVC (KUMMER, 2005). A imagem de TC do crânio de pacientes com AVC não é difícil de verificar, no entanto, os indícios da ocorrência de um AVC não são auto-evidentes. Kummer, Bozzao e Manelfe (2012) destacam que para qualquer profissional da área médica a análise de um exame de TC requer um treinamento específico (em radiologia) e conhecimento sobre como reconhecer a anatomia

e patologia do AVC, bem como ter o conhecimento sobre as condições físicas de contraste de imagem.

Vários pesquisadores têm utilizado a análise computadorizada de atributos extraídos por inspeção visual no auxílio à tomada de decisão, quanto ao encaminhamento do tratamento do paciente. Uma ampla variedade de estudos tem sido propostos no sentido de extrair informações de imagens médicas, identificando especificidades que não são evidentes a olho nu, e possibilitando o alerta da ocorrência de doenças. Neste sentido, Przelaskowski *et al.* (2007) utilizam técnicas de PDI baseadas em *wavelet* para aumentar o contraste local e a sensibilidade no diagnóstico de AVC, a qual passou de 12,5% para 56,3% na detecção do AVC pelo médico especialista.

Já o estudo de Charnovski (2003) propôs uma abordagem computacional para analisar o fluxo cerebral de pacientes acometidos por AVC do tipo isquêmico. Em seu estudo o autor utiliza imagens de TC dinâmica com agente de contraste iodado. A fim de melhorar a detecção de AVC isquêmico, Lee *et al.* (2006) propuseram um método denominado filtro de suavização parcial adaptativo (*adaptive partial smoothing filter*, APSF) que utiliza técnicas de PDI em imagens de TC para suavizar o ruído local com preservação das bordas dos objetos da imagem. Os resultados dos experimentos deste estudo mostraram melhores resultados quanto a detecção precoce de sinais de AVC.

Além de estudos que ajudem no aprimoramento da imagem para análise do especialista, pode-se citar estudos que envolvem classificação, localização e segmentação de regiões com AVC.

O trabalho de Peng *et al.* (2008) propõe um classificador utilizando Máquina de Vetores Suporte para análise dos tipos de AVC. Já o trabalho desenvolvido por Restum (2008) aplica técnicas de PDI e Reconhecimento de Padrões na identificação de áreas hiperdensas e/ou hipodensas anormais em exames de TC de crânio em conjunto com o histórico clínico do paciente para auxílio na decisão do tratamento clínico de AVC. As inovações propostas são a utilização de Rede Neural Artificial (RNA) com entradas que se baseiam no histórico do paciente e na análise das imagens de TC. Podem ser citados alguns outros estudos de doenças cerebrais por classificação dos *pixels* da imagem de entrada, tais como os trabalhos de Maier *et al.* (2015) and Dalca *et al.* (2014). Maier *et al.* (2015) propuseram uma abordagem baseada na estrutura *Extra Tree forest* para a classificação do *voxelwise*, a fim de usar a intensidade característica derivada a partir da imagem de entrada. No entanto, a detecção foi restrita a sequências específicas de IRM. Dalca *et al.* (2014) propuseram um modelo generativo para extrair padrões espaciais e propriedades de intensidade, a fim de segmentar patologias

cerebrovasculares em pacientes com AVC.

O trabalho de Tang, Ng e Chow (2011) apresenta uma abordagem para detecção precoce de pequenas lesões de AVC isquêmico baseado em características de textura, extraídas com a matriz de co-ocorrência. Para localização da região que apresenta sutis mudanças de intensidade é utilizado o método *Circular Adaptive Region of Interest* (CAROI). A contribuição mais promissora deste estudo foi o de fornecer um esquema para um diagnóstico preciso para pequenas lesões de AVC isquêmico.

Quanto a trabalhos focados na segmentação, pode-se citar o estudo de Matesin, Loncaric e Petravic (2001a), em que propuseram um método para segmentação automática e rotulagem de lesões de AVC em imagens de TC do crânio. O método é composto de três etapas. O primeiro passo é a determinação automática do eixo de simetria da cabeça, o segundo consiste em aplicar crescimento de região para segmentar as regiões que têm brilho uniforme. Por fim, o terceiro passo é a utilização das características destas regiões, como brilho, área e posição em relação ao eixo de simetria que são usados para rotular as regiões como fundo, caixa craniana, matéria cinzenta/branco e o AVC. Os resultados dos experimentos demonstraram a viabilidade e a precisão do método proposto.

Já o trabalho desenvolvido por Rajini e Bhavani (2013) descreve uma nova abordagem para detecção automática de AVC isquêmico usando segmentação e extração de atributos de imagens de TC, na qual os tecidos acometidos pelo AVC são separados dos tecidos saudáveis. A abordagem proposta é baseada na detecção da linha média do cérebro e uso de classificadores para detecção de *pixels* da região do AVC. Recentemente Matesin, Loncaric e Petravic (2001b) desenvolveram uma abordagem que identifica a ocorrência de um AVC por meio do melhoramento da qualidade das imagens de TC usando um aperfeiçoamento da técnica *Contrast Limited Adaptive Histogram Equalization* (CLAHE) em conjunto com extração de características estatísticas.

1.2 Motivação

O Acidente Vascular Cerebral, popularmente conhecido como derrame, é a segunda causa mais comum de morte de acordo com *Global Burden of Disease* (LOZANO *et al.*, 2013) e foi umas das principais causas de afastamento por invalidez no mundo em 2010. A Organização Mundial de Saúde (OMS) estima que 17,5 milhões de pessoas morreram de doenças cardiovasculares em 2012, o que corresponde a 31% de todas as mortes globais. Dessas mortes, 6,7 milhões foram atribuídas ao Acidente Vascular Cerebral (WORLD HEALTH

ORGANIZATION, 2015). Além disso, em 2012, as doenças cardiovasculares e o AVC estavam entre as três principais causas da mortalidade prematura no mundo (MENDIS *et al.*, 2014). No Brasil, o AVC mata cerca de 87 mil pessoas por ano. Esta doença é a principal causa de morte e incapacidade no país, o que tem um impacto econômico e social significativo (LOTUFO, 2005). A importância do tema de estudo deste trabalho é proporcional aos impactos causados por doenças cardiovasculares, visto que este tema comumente possui prioridade mais baixa em serviços clínicos e de pesquisa do que outras doenças com impacto semelhante ou reduzido sobre a saúde pública (ROTHWELL, 2001; PARTY, 2012).

Com o objetivo de auxiliar o diagnóstico baseado em imagens médicas do cérebro, vários estudos têm sido desenvolvidos nos últimos anos, tais como: segmentação de tumor cerebral (NJEH; AYED; HAMIDA, 2012; MUSTAQEEM; JAVED; FATIMA, 2012; KAVITHA; CHELLAMUTHU, 2013; AL-FARIS *et al.*, 2014; SAYAH; TIGHIOUART, 2014; BENSON; LAJISH; RAJAMANI, 2015), detecção e classificação automática de acidente vascular cerebral utilizando imagem TC do crânio (CHAWLA *et al.*, 2009; HAJIMANI *et al.*, 2013) e a segmentação automática de lesões cerebrais utilizando imagem de ressonância magnética ponderada por difusão (SAAD; ABDULLAH, 2012).

Neste campo de estudo destaca-se a segmentação por métodos de contornos ativos. Estas técnicas são baseadas na teoria de evolução de curvas, em que uma curva inicial se propaga ao longo do tempo a fim de delimitar uma região de interesse. O método *level set* é classificado como contorno ativo implícito (ou geométrico) (KIMIA; TANNENBAUM; ZUCKER, 1995). Nesta técnica, o contorno é representado implicitamente em uma superfície de dimensão mais elevada, normalmente atribuída como função de *level set*, em que o contorno se deforma por iterações sucessivas até sua consequente estabilização. Uma das vantagens é que esta técnica é capaz de agir eficazmente em mudanças topológicas que podem surgir no processo de propagação da curva. Nos últimos anos, um grande volume de trabalhos utilizando métodos *level set* tem sido proposto para abordar uma ampla gama de problemas de segmentação de imagem e visão computacional (LI *et al.*, 2005, 2013; WANG; FRIMMEL; SMEDBY, 2014).

O método *level set* tem apresentado resultados promissores em outras aplicações, como segmentação de vértebra utilizando TC (HUANG *et al.*, 2013), segmentação do ventrículo esquerdo em ressonância magnética cardíaca (RMC) (FENG *et al.*, 2013), segmentação de fígado utilizando TC (LEE *et al.*, 2007) e IRM (CHEN *et al.*, 2009; SMEETS *et al.*, 2010). Em aplicações relacionadas a imagens do cérebro, o método *level set* tem sido aplicado no mapeamento de estruturas cerebrais (LEOW *et al.*, 2005), segmentação do cérebro neonatal utilizando IRM (WANG *et al.*, 2014), segmentação de tumor no cérebro em imagens de IRM

(THAPALIYA *et al.*, 2013), e na segmentação da região hemorrágica de AVC (BHADAURIA; SINGH; DEWAL, 2013; BHADAURIA; DEWAL, 2014), assim se apresenta como abordagem promissora na segmentação de AVC.

Neste trabalho, é proposto uma nova abordagem do *level set* para a segmentação de Acidente Vascular Cerebral Hemorrágico em imagens TC do crânio. Nossa abordagem é denominada *level set* baseado nas densidades radiológicas do crânio combinado com a Janela de Parzen ($LSDRC_{parzen}$). A abordagem tem duas contribuições principais: a primeira é a iniciação automática do *level set* zero dentro do AVC, com base na análise das densidades radiológicas do cérebro. A segunda é aplicar o método *level set* utilizando uma abordagem de estimação não paramétrica baseada na Janela de Parzen para segmentação do AVC hemorrágico. A região encontrada na primeira etapa é utilizada como o *level set* zero da segunda etapa. Como em Li, Li e Zhang (2012), a evolução do contorno ativo na abordagem do *level set* não depende do gradiente da imagem nem das médias dentro e fora dos objetos, como nos modelos clássicos de *level set*. No entanto, a nossa abordagem depende da distribuição de probabilidade da Janela de Parzen associada com as densidades radiológicas cerebrais para evoluir o contorno ativo. O objetivo é tornar o modelo proposto menos sensível ao ruído da imagem.

1.3 Objetivos

1.3.1 Objetivo Geral

Este trabalho tem como objetivo propor, implementar e avaliar um algoritmo *level set* para a segmentação de Acidente Vascular Cerebral Hemorrágico em imagens de TC do crânio utilizando uma abordagem de estimação não paramétrica que se baseia na Janela de Parzen.

1.3.2 Objetivos Específicos

Dentre os objetivos específicos a serem atingidos nesta dissertação estão:

- propor uma abordagem de iniciação do método *level set* baseada nas densidades radiológicas do cérebro;
- avaliar e comparar o método de iniciação com outros propostos na literatura;
- propor um algoritmo de *level set* utilizando uma abordagem de estimação não paramétrica baseada na Janela de Parzen;

- avaliar a abordagem proposta na segmentação do AVC, considerando a segmentação do médico especialista como ideal;
- comparar a abordagem proposta com métodos de segmentação consolidados, e outros recentes, existentes na literatura.

1.4 Contribuições e Produção Científica

As contribuições desta dissertação são as seguintes:

- um algoritmo de *level set* utilizando uma abordagem de estimação não paramétrica baseada na Janela de Parzen;
- iniciação automática do *level set* baseado nas densidades radiológicas em imagens de TC do crânio;
- construção de um banco de imagens de AVC hemorrágico e disponibilização de suas respectivas segmentações obtidas por um médico especialista, que será disponibilizado on-line juntamente com todos os resultados obtidos neste estudo.

Os seguintes artigos são resultados dessa pesquisa:

- Elizângela de Souza Rebouças; Alan Magalhães Braga; Regis Cristiano Pinheiro Marques; Pedro Pedrosa Rebouças Filho. **A new approach to calculate the nodule density of ductile cast iron graphite using a *level set*.** In: Journal of the International Measurement Confederation, v. 89, p. 316-321, 2016. - Qualis A2 para Engenharias IV.
- Elizângela de Souza Rebouças; Saulo Anderson Freitas de Oliveira; Regis Cristiano Pinheiro Marques; Pedro Pedrosa Rebouças Filho. **Stroke Detection through a Nonparametric Estimation-Based Level Set Approach based on the Parzen Windows.** In: Conference on Graphics, Patterns and Images (Work in Progress). SIBGRAPI, 2016, São José dos Campos.

A ser submetido:

- Elizângela de Souza Rebouças; Alan Magalhães Braga; Regis Cristiano Pinheiro Marques. *Level set based on brain radiological densities for stroke segmentation in CT images*.

1.5 Organização da Dissertação

O restante desta dissertação está organizada da seguinte forma:

Capítulo 2: contextualização do problema do Acidente Vascular Cerebral, apresentação de métodos de segmentação utilizados na literatura que visam auxiliar o diagnóstico deste tipo doença cardiovascular e o método de estimação não paramétrica com base na Janela de Parzen.

Capítulo 3: apresentação do método de detecção do AVC de forma automática, com base na análise das densidades radiológicas do crânio; e apresentação de uma proposta para iniciação da superfície de *level set*, utilizando uma abordagem de estimação não paramétrica baseada na Janela de Parzen.

Capítulo 4: apresentação das métricas utilizadas para a avaliação dos resultados de segmentação.

Capítulo 5: apresentação dos resultados da segmentação de imagens de AVC do tipo hemorrágico do banco de dados obtidos em parceria com o Hospital do Coração de Fortaleza, criado pelo médico especialista; e avaliação dos resultados por meio de medidas que descrevem a detecção e a acurácia das regiões segmentadas.

Capítulo 6: conclusões do trabalho destacando suas contribuições, bem como perspectivas de trabalhos.

ESTADO DA ARTE

Este capítulo contextualiza o problema do Acidente Vascular Cerebral (AVC), os métodos de segmentação de imagens médicas e o método de estimação não paramétrica Janela de Parzen utilizados neste trabalho. É explorado ainda como técnicas de Processamento Digital de Imagens têm sido utilizadas para auxiliar o diagnóstico deste tipo de doença cardiovascular.

2.1 Acidente Vascular Cerebral

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

O AVC constitui um frequente e significativo problema de saúde, com elevados índices de morbidade e mortalidade, e por isso tem sido um dos maiores desafios para a saúde pública e a medicina como um todo. Esta doença afeta os vasos que fornecem sangue para o cérebro. Segundo Manzi *et al.* (2003) e Gonçalves *et al.* (2004), o AVC ocorre tanto pela falta de fornecimento de sangue para uma determinada área do cérebro, conhecido como AVC isquêmico (AVCi), quanto pelo sangramento devido ao rompimento de um vaso sanguíneo, AVC hemorrágico (AVCh), como mostra a Figura 2.

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

O foco desse estudo é o AVC do tipo hemorrágico (AVCh), que é responsável por 40% de todas as mortes por AVC. Devido à elevada taxa de mortalidade, a detecção rápida da




Figura 2: Diferenciação dos tipos de AVC (AMERICAN HEART ASSOCIATION AND AMERICAN STROKE ASSOCIATION, 2016).

região hemorrágica é crucial para o diagnóstico clínico (SUN *et al.*, 2015). A Tomografia Computadorizada, que é rápida e menos dispendiosa do que outros exames, ainda é o exame mais comumente solicitado para avaliar pacientes com suspeita de AVC. Este exame permite ao especialista verificar a severidade dos danos através da avaliação visual (MESSAY; HARDIE; ROGERS, 2010). No entanto, nas primeiras horas da evolução do AVC, as alterações nos exames de TC são sutis, o que torna mais difícil o diagnóstico pelo médico especialista. Além disso, a abordagem padrão com base na delimitação manual da lesão, é demorada e depende do operador (GILLEBERT; HUMPHREYS; MANTINI, 2014).

As imagens obtidas a partir de uma TC apresentam valores ligados à densidade radiológica de cada estrutura imageada. Estes valores são dispostos em uma escala chamada escala Hounsfield, como mostra a Figura 3, com valores de -1000 a 1000 , expressos em Unidade Hounsfield (UH)(FREITAS, 2013).

A Unidade Hounsfield é uma escala comumente usada na TC para expressar os valores dos *pixels* de forma padronizada e conveniente. As unidades de Hounsfield, criadas por Godfrey Hounsfield, são obtidas a partir de uma transformação linear dos coeficientes de atenuação dos tecidos medidos para uma escala adimensional (HOUNSFIELD, 1980). Nessa escala, a radiodensidade da água destilada sob condições-padrão de temperatura e pressão (CPTP) é definida como valor 0 UH, enquanto a radiodensidade do ar nas CPTP é definida como -1000




Figura 3: Faixas da escala de atenuação em Unidades Hounsfield (FREITAS, 2013).

UH (BUZUG, 2008). Os valores de cada *pixel* em Unidade Hounsfield em relação ao coeficiente de atenuação linear da água é dado por:

$$UH = 1000 \times \frac{\mu - \mu_{H_2O}}{\mu_{H_2O}}, \quad (2.1)$$

em que μ é o coeficiente de atenuação linear do tecido e μ_{H_2O} é o coeficiente de atenuação linear da água.

Quando uma pessoa é afetada por um AVC, o cérebro é danificado e os valores em UH dos tecidos cerebrais são alterados, não obedecendo padrões pré-estabelecidos, e isto além de alterar os valores das densidades radiológicas também geram sintomas clínicos. Por exemplo, alguém que teve um pequeno derrame pode ter apenas pequenos problemas como fraqueza temporária de um braço ou perna. Já pessoas que têm regiões maiores afetadas podem ser permanentemente paralisadas de um lado do seu corpo ou podem perder a capacidade de falar. Algumas pessoas se recuperam completamente das sequelas causadas pelo AVC, entretanto mais de 2/3 dos sobreviventes terão algum tipo de deficiência (WORLD HEALTH ORGANIZATION, 2004).

2.2 Métodos de Segmentação

Nesta seção, são descritos os métodos de segmentação utilizados na comparação dos resultados obtidos pela abordagem proposta em relação a análise de um radiologista na segmentação da região do cérebro afetada pelo AVCh em imagens de TC do crânio. A segmentação do especialista, é considerada neste trabalho como padrão ouro (*ground truth*).

2.2.1 Método Crescimento de Região

O método Crescimento de Região (CR) é uma técnica para extrair uma região de *pixels* conectados de uma imagem com base em alguns critérios pré-definidos (PHAM; XU; PRINCE, 2000). O processo começa a partir de um *pixel* semente que é selecionado dentro da região de interesse, podendo esta inicialização ser manual ou automática.

O *pixel* semente é rotulado como o primeiro ponto da região de interesse, que então cresce por iterações sucessivas agregando *pixels* vizinhos à região obedecendo uma regra de similaridade (SALMAN; GHAFOR; HADI, 2015). Tal regra para adição de novos *pixels* pode ser baseada em diversas características da imagem, como textura, tom de cinza, luminosidade, entre outras (GONZALEZ; WOODS, 2010). A análise da vizinhança para adicionar um *pixel* semente a uma região conectada depende do problema e das características da imagem de entrada.

O processo de crescimento por agregação de novos *pixels* se encerra quando a região não cresce por iterações sucessivas, sendo então a região obtida adotada como resultado da segmentação do objeto de interesse (ZUCKER, 1976). Em algumas aplicações existem vários objetos a serem segmentados, sendo assim ao concluir a segmentação de um objeto, outra semente é inicializada e o processo reinicia, sendo executado até todos os objetos de interesse serem segmentados (ARAUJO, 2010). A Figura 4 exemplifica um processo de segmentação utilizando o método Crescimento de Região, em que as etapas são numeradas de (1) a (11). A etapa (1) mostra uma imagem sintética como imagem de entrada, (2) apresenta com mais detalhes os tons de cinza da imagem de entrada. A etapa (3) representa a seleção do *pixel* semente dentro da região de interesse e as etapas (4) a (9) demonstram o processo de agregação dos *pixels* vizinhos baseado no valor de intensidade do *pixel*. Já as etapas (10) e (11) mostram o resultado de segmentação do objeto e a imagem de saída, respectivamente.

Este método tem sido aplicado na segmentação de diversos objetos em imagens digitais,




Figura 4: Exemplo de segmentação de um objeto utilizando o método Crescimento de Região: 1) Imagem de entrada; 2) Informações dos tons de cinza da imagem de entrada; 3) Escolha do *pixel* semente; 4)-9) Processo de agregação de *pixels* vizinhos a região de interesse; 10) Objeto segmentado e 11) Imagem de saída.

entretanto vale ressaltar seu uso recente em imagens médicas do cérebro (SALMAN; GHAFOR; HADI, 2015; ROUHI *et al.*, 2015), segmentação de tumores no cérebro em imagens de ressonância magnética (KAVITHA; CHELLAMUTHU, 2013; AL-FARIS *et al.*, 2014; SAYAH; TIGHIOUART, 2014), lesões cerebrais (SAAD; ABDULLAH, 2012) e também de acidente vascular cerebral (BHADAURIA *et al.*, 2015).

2.2.2 Método Watershed

O conceito da transformada de Watershed (WS) foi originalmente proposto por Digabel e Lantuéjoul (1978), Serra e Soille (2012) e, posteriormente, elaborado por Beucher e Lantuéjoul (1979). Esta técnica tem sido utilizada por diversos autores para segmentar diferentes tipos de objetos em imagens digitais, podendo citar a segmentação das vias aéreas (RIBEIRO *et al.*, 2013), segmentação dos lóbulos pulmonares (DAGHER; TOM, 2008; SHOJAI; ALIREZAIE; BABYN, 2005), segmentação celular (CHEN; ZHANG, 2010), na detecção de câncer cervical (GARG; UROOJ; VIJAY, 2015), de objetos em imagens abdominais (MASOUMI *et al.*,

2012), de tumores no cérebro em imagens de ressonância magnética (MUSTAQUEEM; JAVED; FATIMA, 2012; BENSON; LAJISH; RAJAMANI, 2015), bem como na segmentação de AVC (SARMENTO *et al.*, 2015), que é o objeto de estudo deste trabalho.

A idéia básica desta técnica consiste em considerar a imagem de entrada como uma superfície topográfica, na qual cada *pixel* corresponde a uma “posição”. A intensidade da escala de cinza determina a “altitude”. Do ponto de vista topográfico, a imagem terá “vales” e “picos” com alturas variadas (AICHA; ABDELHAFID, 2012). Usando os conceitos de relevo topográfico, podem ocorrer dois tipos de inundação: imersão ou precipitação. A simulação de imersão ocorre quando furos são definidos no mínimo de cada bacia de captação, e a água inunda através dos “buracos” para formar pequenos lagos. Enquanto a precipitação é similar a água da chuva caindo sobre o terreno (CHIEN; HUANG; CHEN, 2003). Desta analogia, pode-se identificar bacias hidrográficas definidas por um mínimo regional, onde uma barreira forma a linha divisória das bacias. Depois que toda a superfície é inundada, essas represas correspondem às bacias hidrográficas da imagem de entrada (GRAU *et al.*, 2004). A Figura 5 exemplifica um processo de segmentação utilizando o método Watershed.




Figura 5: Exemplo de segmentação obtida pelo método Watershed: 1) imagem original; 2) vista topográfica; 3) a 4) duas fases da inundação; 5) resultado de novas inundações; 6) começo da fusão da água de duas bacias hidrográficas (uma pequena barragem foi construída entre elas); 7) barragens maiores; e 8) linhas finais segmentação (GONZALEZ; WOODS, 2010).

A etapa (1) apresenta uma imagem em nível de cinza e a etapa (2) é a vista topográfica em que os valores de intensidade estão relacionados analogamente à altura das “montanhas”. As etapas (3) a (7) exemplificam as fases de inundação na qual a “água”, vista em cinza-claro, inicia cobrindo a área que corresponde ao fundo escuro da etapa (2) e continua inundando até

que barragens maiores são feitas ao redor das bacias hidrográficas. Este processo continua até atingir o maior valor de intensidade da imagem. O resultado final é mostrado na etapa (8), em que as linhas de 1 *pixel* de espessura foram sobrepostas na imagem original (GONZALEZ; WOODS, 2010).

A grande vantagem da transformada de Watershed é a sua velocidade de processamento, mas, devido ser bastante sensível às variações de imagens, o resultado esperado pode não ser satisfatório, necessitando de pequenos ajustes na sua configuração.

2.2.3 Algoritmo de Agrupamento *Fuzzy C-means* (FCM)

Agrupamento *fuzzy* permite que os dados fiquem agrupados em dois ou mais aglomerados. Esta técnica de agrupamento não supervisionada é frequentemente utilizada em segmentação de imagens médicas. *Fuzzy C-means* (FCM) é um dos métodos de agrupamento *fuzzy* mais populares usado na segmentação de imagens devido às suas características robustas (WANG; BU, 2010).

Uma imagem pode ser representada em vários espaços de características e o FCM segmenta a imagem em objetos, agrupando os *pixels* semelhantes nesses espaços de características. O agrupamento é obtido pela minimização iterativa de uma função custo que depende da distância euclidiana dos *pixels* para os centros dos grupos no domínio das características. O objetivo da segmentação é dividir uma imagem em regiões significativas (BEZDEK, 1981).

Mais formalmente, a segmentação é um processo de particionamento de uma imagem em D regiões conectadas, tal que cada região é homogênea no que diz respeito a alguns critérios. A função FCM padrão para particionar os dados $\{z_i\}_{i=1}^N$ em D regiões é dada por

$$J = \sum_{i=1}^N \sum_{j=1}^D u_{ij}^m \|z_i - c_j\|^2, \quad (2.2)$$

em que N é o número de *pixels* a serem rotulados, isto é, o número de *pixels* na imagem. O operando z_i representa um *pixel* da imagem, c_j é o *pixel* central da j -ésimo região, u_{ij} é a função de pertinência do i -ésimo *pixel* com respeito ao j -ésimo região e m é o parâmetro de controle *fuzzy* do resultado de segmentação, em que Bhadauria, Singh e Dewal (2013) utilizaram $m = 2$.

A função de pertinência descreve o quanto, ou seja, o grau de pertinência de um *pixel* em relação à uma região específica. Esta função tem a seguinte propriedade:

$$\sum_{j=1}^D u_{ij} = 1 \forall j; u_{ij} \in [0,1]. \quad (2.3)$$

A função de pertinência e os centróides nos agrupamentos c_j podem ser calculados, respectivamente, de forma iterativa por:

$$u_{ij} = \frac{\|z_i - c_j\|^{\frac{-2}{m-1}}}{\sum_{j=1}^D \|z_i - c_j\|^{\frac{-2}{m-1}}} \quad (2.4)$$

e

$$c_j = \frac{\sum_{i=1}^N u_{ij}^m z_i}{\sum_{i=1}^N u_{ij}^m}. \quad (2.5)$$

O FCM tem sido utilizado com sucesso na segmentação de imagens médicas. No entanto, uma vez que o FCM padrão não considera qualquer informação espacial em uma imagem, o mesmo sofre com a desvantagem de ser sensível ao ruído e à outros artefatos. Recentemente, muitos pesquisadores têm incorporado informação espacial local no FCM padrão. Uma das características importantes de uma imagem é que os *pixels* vizinhos são altamente correlacionadas, isto é, a sua probabilidade de pertencer ao mesmo conjunto é elevado (CHUANG *et al.*, 2006).

2.2.4 Level Set

A formulação da teoria de *level set* proposta por Sethian (1999) é baseada na equação de Hamilton-Jacobi. Esta teoria afirma que uma curva fechada $\vec{\phi}: \mathbb{R}^2 \times \mathbb{R}^+ \rightarrow \mathbb{R}$ evolui devido a um campo de velocidade $\pm F\vec{\eta}$, em que $(\pm\vec{\eta})$ é o vetor unitário que é perpendicular a $\vec{\phi}$, como ilustra a Figura 6.

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

$$\vec{\phi}(s, t) = \{\mathbf{x} | \psi(\mathbf{x}, t) = 0\}, \mathbf{x} \in \mathbb{R}^2, \quad (2.6)$$

em que $s \in \mathbb{R}^2$ é a coordenada da curva $\vec{\phi}$ e $t \in \mathbb{R}^+$ é o tempo de evolução. Assim, uma curva fechada $\vec{\phi}(s, t)$ é representada implicitamente como o nível zero de uma função *level set* $\psi(\mathbf{x}, t)$,




Figura 6: Propagação de uma curva fechada $\vec{\phi}$ submetida a um campo de velocidades $(\pm F\vec{\eta})$ (BRAGA, 2016).

a qual consiste de um conjunto de curvas de níveis que variam de um nível inferior negativo até um nível superior positivo, como ilustra a Figura 7 (MARQUES, 2011). Por convenção, considera-se a região interna à curva $\Omega_1 = \{\mathbf{x} | \psi(\mathbf{x}, t) < 0\}$ e a região externa à curva $\Omega_2 = \{\mathbf{x} | \psi(\mathbf{x}, t) > 0\}$.




Figura 7: Representação da função de *level set* $\psi(\mathbf{x}, t)$ e da curva $\vec{\phi}(s, t)$ Sethian (1999).

O processo de evolução da função de *level set* é expresso como (SETHIAN, 1999):

$$\psi^{k+1} = \psi^k + \Delta t \cdot (F_{prop} + \varepsilon \mathcal{K}) \cdot |\nabla \psi^k|, \quad (2.7)$$

em que ψ^k é a função do *level set*, Δt é o passo de tempo, e $F_{prop} + \varepsilon \mathcal{K}$ é a função de evolução. O operador $|\nabla \psi^k|$ representa a magnitude do gradiente. A função de evolução compreende um termo de propagação (ou velocidade) F_{prop} e um termo de regularização $\varepsilon \mathcal{K}$ com base na curvatura de ψ^k , em que $\varepsilon \in \mathbb{R}$ é uma constante de normalização e a curvatura $\mathcal{K}$ é calculada como (SETHIAN, 1999):

$$\mathcal{K} = \frac{\psi_{xx}\psi_y^2 - 2\psi_x\psi_y\psi_{xy} + \psi_{yy}\psi_x^2}{\sqrt{(\psi_x^2 + \psi_y^2)^3}}. \quad (2.8)$$

Os índices (x,y) e (xx,yy,xy) na Eq. (2.8) indicam as derivadas centrais de primeira e segunda ordem de ψ^k , respectivamente.

O *level set* zero é o estado inicial da superfície (ou função *level set*) e consiste de uma imagem com as mesmas dimensões da imagem a ser segmentada. O *level set* zero pode ser composta por um único elemento ou por vários elementos desconectados, os quais podem se unir ou se dividir durante a evolução, a fim de delimitar a região de interesse. A Figura 8 apresenta dois exemplos de *level set* zero em que a curva $\vec{\phi}(s,0)$ está em azul, Ω_1 em branco e Ω_2 em preto. A Figura 8a mostra um *level set* zero em que Ω_1 é composto por apenas um elemento e a Figura 8b exibe um *level set* zero em que Ω_1 é composto por vários elementos desconectados.




Figura 8: Possíveis estados iniciais da superfície ou *level set* zero: a) com apenas um elemento; e b) com múltiplos elementos.

2.2.4.1 Algoritmo de *Level set* com Fuzzy C-means ($LSFCM_{evol}$)

A abordagem proposta por Bhadauria, Singh e Dewal (2013) utiliza as características tanto de FCM explicado na Subseção 2.2.3 quanto o *level set* proposto por Li *et al.* (2008). Nesta abordagem, os resultados do método FCM são utilizados para inicializar o método *level set*, bem como para estimar os parâmetros que controlam a evolução do algoritmo *level set*, sendo neste trabalho denominado "evolução do *level set* baseado no algoritmo *Fuzzy C-means*" ($LSFCM_{evol}$).

Li *et al.* (2008) propuseram um modelo baseado em região que usa informações de intensidade das regiões locais em uma escala controlável. A formulação *level set* é dada por:

$$\frac{\partial \psi}{\partial t} = \delta_\varepsilon(\psi)(-\lambda_1 e_1 + \lambda_2 e_2) + \nu \delta_\varepsilon(\psi) \operatorname{div} \left(\frac{\nabla \psi}{|\nabla \psi|} \right), \quad (2.9)$$

em que, o primeiro termo é responsável por propagar a curva em direção as bordas do objeto e o segundo termo é responsável pela suavização da curva. λ_1 e λ_2 são os coeficientes de ponderação dos dados do primeiro termo, e_1 e e_2 são funções de energia interna e externa à curva e ν é o coeficiente de ponderação do segundo termo.

Em métodos *level set* tradicionais, vários parâmetros que controlam a evolução do *level set* são inseridos manualmente e seus valores variam dependendo do problema. Neste método, todos os parâmetros de controle são adaptativamente calculados a partir dos resultados do FCM. A área e o comprimento do contorno produzido pelo FCM são calculados por (BHADAURIA; SINGH; DEWAL, 2013):

$$C_{Area}(\psi \geq 0) = \int_{\Omega} H(\psi(x,y)) dx dy \quad (2.10)$$

e

$$C_{comprimento}(\psi = 0) = \int_{\Omega} \delta_\varepsilon(\psi(x,y)) |\nabla \psi(x,y)| dx dy, \quad (2.11)$$

em que a função Heaviside $H_{(\psi)}$ e a função Dirac $\delta_\varepsilon(\psi)$ são definidas em (BHADAURIA; SINGH; DEWAL, 2013).

O parâmetro do passo de tempo Δt é estimado por (BHADAURIA; SINGH; DEWAL, 2013):

$$\Delta t = \frac{C_{Area}}{C_{comp}}. \quad (2.12)$$

O primeiro termo da Equação (2.9) acelera a atração da função do *level set* para o objeto desejado. Este termo é composto de dois coeficientes de ponderação λ_1 e λ_2 , através das regiões externa e interna e do contorno, respectivamente. O valor desses pesos devem ser os mesmos para conduzir a uma competição justa entre as regiões interna e externa do contorno durante a evolução. Logo, os valores de λ_1 e λ_2 são calculados a partir dos resultados do FCM por:

$$\lambda_1 = \lambda_2 = 0,5 - u_{i,j}, \quad (2.13)$$

em que $u_{i,j}$ é o valor da função de pertinência para o FCM em cada *pixel* da imagem, dada pela Equação 2.4.

O segundo termo da Equação (2.9) é responsável pela suavização do contorno, sendo o valor de ν estimado como:

$$\nu = 0,2 \Delta t. \quad (2.14)$$

Para realizar a iniciação de forma automática pela abordagem proposta por Bhadauria, Singh e Dewal (2013), o método detecta a área de interesse usando algoritmo de agrupamento FCM. Nesta fase, são realizadas operações morfológicas de erosão e dilatação para se livrar de falsos e atípicos pequenos objetos na imagem. Depois de ter realizado as operações morfológicas, os resultados do FCM são usados para iniciar a função de *level set*, bem como para estimar os parâmetros que controlam a evolução da função. Sabendo que $u_{i,j}$ é a função de pertinência para o FCM, o objeto de interesse pode ser extraído a partir da imagem binária $B_{i,j}$, determinada por (BHADAURIA; SINGH; DEWAL, 2013):

$$B_{i,j} = \begin{cases} 1, & u_{i,j} \geq b_0; \\ 0, & \text{caso contrário,} \end{cases} \quad (2.15)$$

em que $b_0 \in (0,1)$ é o limiar de ajuste e para este método foi escolhido 0,5.

2.2.4.2 Algoritmo de *Level Set* com base no Método de Propagação Coerente (LSCPM)

Wang, Frimmel e Smedby (2011) e Wang, Frimmel e Smedby (2014) propuseram uma função de velocidade monotônica periódica para acelerar o algoritmo *level set* (SETHIAN, 1999), o que permite que o contorno de segmentação se expanda em um período e encolha no próximo período, ou seja, propagação coerente, sendo neste trabalho este algoritmo denominado *Level Set* com base no Método de Propagação Coerente (LSCPM). Esta estratégia evita a instabilidade do contorno, que ocorre frequentemente durante a propagação do contorno, quando determinados pontos se movem mais rapidamente do que seus pontos vizinhos. Isto é devido à força da curvatura que os moverá para atrás mesmo que a vizinhança inteira eventualmente mova-se para a frente (WANG; FRIMMEL; SMEDBY, 2011). Usando a propagação coerente, estes pontos mais rápidos permanecerão em suas posições à espera de seus vizinhos para recuperar o atraso.

A propagação coerente permite o uso de um algoritmo de *level set* de banda estreita modificado que impede a computação que demanda muito tempo em pontos que atingiram a fronteira da região de interesse (WANG; FRIMMEL; SMEDBY, 2011). O processo de segmentação termina, naturalmente, quando todos os pontos no contorno estão estacionários.

Wang, Frimmel e Smedby (2011, 2014) têm aplicado o algoritmo LSCPM na segmentação da artéria esplênica, aorta e fígado. Este algoritmo, segundo os autores, é cerca de 10 vezes mais rápido do que as abordagens incluídas no *software* Snap para segmentar imagens médicas (ITK) (YUSHKEVICH *et al.*, 2006). O método proposto foi utilizado através do *plugin* MIA para Osirix ¹.

2.2.4.3 Algoritmo rápido de *Level Set*

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

$$f(\psi) = \mathcal{K}|\nabla\psi|, \quad (2.16)$$

em que $\mathcal{K}$ é descrito pela Eq. (2.8) e $|\nabla\psi|$ é a magnitude do gradiente.

A formulação original da técnica *level set*, dada pela Eq. (2.7), utiliza a EDP da curvatura para fins de regularização da frente. Como visto na Seção 2.2.4, o cômputo de $\mathcal{K}$ envolve derivadas de primeira e segunda ordem, o que é computacionalmente demorado. A fim de reduzir o custo computacional, o algoritmo *level set* proposto por Braga (2016) utiliza o filtro da mediana, que consiste de um filtro não paramétrico, para regularizar a frente ao invés de utilizar a curvatura $\mathcal{K}$.

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

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

$$\psi_{\bar{r}}^{k+1} = \psi^k + \Delta t \left[\max(F, 0)(\psi^k \oplus E) - \min(F, 0)(\psi^k \ominus E) \right], \quad (2.17)$$

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

¹<http://www.mia-solution.com>.

morfológico. Após o cômputo de $\psi_{\vec{r}}$, a superfície é regularizada por

$$\psi^{k+1} = \text{MedFilt}_4 \left[\psi_{\vec{r}}^{k+1} \right], \quad (2.18)$$

em que o operador $\text{MedFilt}_4[\cdot]$ indica uma filtragem mediana com uma vizinhança de conectividade 4.

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

2.3 Janela de Parzen

A Janela de Parzen (THEODORIDIS; KOUTROUMBAS, 2009) é um método de estimação não paramétrica, que não assume uma distribuição de probabilidade dos dados. O método calcula a probabilidade de um ponto z pertencer a um hipercubo $R = \{z_i\}_{i=1}^k$ de dimensionalidade d como

$$p(z) = \frac{1}{k} \sum_{i=1}^k \varphi \left(\frac{z_i - z}{h} \right), \quad (2.19)$$

em que φ é a função *kernel* usada para limitar a vizinhança, h é o tamanho da aresta do hipercubo e k é o número de *pixels* de R .

O *kernel* Gaussiano, que é um dos mais utilizados na literatura, possui algumas propriedades importantes. Primeiramente a função Gaussiana é suavizada e, portanto, a função de estimação de densidade $p(z)$ também varia suavemente. Em segundo lugar, se assumirmos uma forma especial da família Gaussiana na qual a função é radialmente simétrica, a função pode ser completamente especificada somente por um parâmetro de variância. Assim $p(z)$ pode ser expresso como uma mistura de *kernels* Gaussianos radialmente simétricos (YEUNG; CHOW, 2002). O *kernel* Gaussiano pode ser definido como (BISHOP, 2006):

$$\varphi(z_i, z) = \frac{1}{\sqrt{(2\pi)^d |\Lambda|}} \exp \left(-\frac{(z_i - z)^T \Lambda^{-1} (z_i - z)}{2} \right), \quad (2.20)$$

em que z e z_i são vetores com d componentes, Λ representa a matriz de covariância $d \times d$ e o $|\Lambda|$ é o determinante de Λ .

2.4 Conclusão do capítulo

Neste capítulo foi contextualizado o problema do AVC, a importância de diagnosticar precocemente esta doença, e principalmente delimitar a região afetada por este quadro clínico, que é o foco deste estudo. Em seguida, foram apresentados métodos de segmentação já usados para este fim, ou que se apresentem como promissores para esta finalidade. Além disso, foi apresentado o método de estimação não paramétrica com base na Janela de Parzen.

O próximo capítulo apresenta a metodologia proposta para segmentação do AVCh em imagens de TC do crânio, que consiste de uma nova abordagem para iniciação do método de *level set*, bem como de um modelo de propagação de verossimilhança baseado na técnica Janela de Parzen.

METODOLOGIA PROPOSTA

Neste capítulo é proposta uma nova abordagem para segmentar o Acidente Vascular Cerebral Hemorrágico utilizando imagens de Tomografia Computadorizada do crânio, tendo como objetivo o auxílio ao diagnóstico médico.

A abordagem proposta é chamada de *level set* baseado nas densidades radiológicas do cérebro combinado com a técnica Janela de Parzen ($LSDRC_{parzen}$). Esta abordagem possui duas contribuições principais, a iniciação do *level set* zero analisando as densidades radiológicas do cérebro e a estimação não paramétrica com base na Janela de Parzen para segmentação do AVCh. A Seção 3.1 descreve a proposta de iniciação do *level set* zero e a Seção 3.2 a estimação paramétrica da função de densidade de probabilidade com base na estimação de Parzen. Uma visão geral do método proposto é apresentado na Figura 9.

O primeiro estágio da abordagem proposta é segmentar a região interna do crânio, para isso é necessário detectar o crânio que é caracterizado pela presença de osso com valores de densidade radiológica superior à 200 UH. Deste modo, esta região é segmentada utilizando um limiar de 200 UH, e todos os *pixels* com valor superior a este limiar são considerados como região óssea do crânio. A Figura 10a apresenta um exemplo de imagem original de TC do crânio, a Figura 10b apresenta o resultado obtido na limiarização. Utilizando o resultado da limiarização, apenas o objeto de maior área é considerado, como no exemplo da Figura 10c. Por fim, o “buraco” da região obtida na etapa anterior é preenchido por morfologia matemática utilizando a abordagem descrita por Gonzalez e Woods (2010), como mostra a Figura 10d. Apenas a região do “buraco” é utilizada para análise do cérebro e posterior detecção do AVCh.

No estágio seguinte, as faixas de densidade radiológicas do cérebro são analisadas para se definir os *pixels* de iniciação do *level set* zero. Utilizando estes *pixels*, um círculo é inicializado no centróide da região delimitada na etapa anterior. A região então se propaga obedecendo a teoria do *level set* e adotando uma abordagem de estimação não paramétrica da FDP (Função Densidade de Probabilidade) com base na Janela de Parzen. As FDPs das regiões interna e externa à curva são estimadas a cada iteração até que o contorno estabilize.




Figura 9: Fluxograma de execução do método $LSDRC_{parzen}$.




Figura 10: Processo de segmentação do crânio: a) imagem original; b) imagem original limiarizada; c) seleção do objeto de maior área; e f) região do cérebro.

3.1 Análise das Densidades Radiológicas do Crânio

O método de Análise das Densidades dos Tecidos Humanos, utilizado neste trabalho, é a generalização da Análise das Densidades Pulmonares (ADP), proposto por Rebouças Filho *et al.* (2017) para outros atributos de tecidos. São utilizados os valores de UH de tecidos obtidos de imagens de TC para a análise das densidades de tecidos humanos. Neste estudo, Rebouças Filho *et al.* (2017) propuseram uma árvore de decisão baseada na análise da densidade de vizinhança para encontrar a melhor posição para inicializar um modelo de contorno ativo e também para decidir se os objetos de interesse estão dentro ou fora do pulmão sob segmentação.

Entretanto, o método de extração ADP somente pode ser usado em imagens de TC do tórax. Por esta razão, neste trabalho, é apresentado o ADP generalizado, sendo denominado de ADH (Análise das Densidades dos Tecidos Humanos), que pode ser considerado para extração de atributos em qualquer tipo de imagem médica. Generalizando o método de Análise das Densidades Pulmonares para analisar imagens do crânio, tem-se as faixas de densidades para as imagens de TC do crânio em cada vizinhança analisada, como em (YOUSEM; GROSSMAN, 2010; NAIDICH *et al.*, 2012):

- d_0 - sangue (56 a 76 UH)
- d_1 - ar (-1005 a -995 UH)
- d_2 - osso (200 a 2000 UH)
- d_3 - fluido espinhal (-5 a +5 UH)
- d_4 - massa cinzenta do cérebro (32 a 41 UH)
- d_5 - massa branca do cérebro (23 a 34 UH)

- d_6 - áreas não classificadas.

A região de análise utiliza as faixas de densidades humana, proposto por Rebouças Filho, Cortez e Holanda (2011), para iniciar os contornos ativos no segmento de imagens pulmonares. Considerando esta abordagem, a generalização proposta calcula a probabilidade de sete classes d_k , onde k varia de 0 a 6. A classe d_6 se refere às áreas não classificadas, que são as densidades que não correspondem aos intervalos anteriores.

Deste modo, considerando (x, y) as coordenadas de um *voxel*¹, o número de *voxels* com densidades presentes em cada classe d_k é determinado por:

$$f_k(x, y) = \sum_{l=-n}^n \sum_{m=-n}^n R_k(x-l, y-m), \quad (3.1)$$

em que n define o tamanho da vizinhança $R(x, y)$ analisada, sendo:

$$R_k(x, y) = \begin{cases} 1, & \lim_{inf}(d_k) < z(x, y) < \lim_{sup}(d_k), \\ 0, & \text{caso contrário,} \end{cases} \quad (3.2)$$

em que $z(x, y)$ representa cada *pixel* da imagem em análise, $\lim_{inf}(d_k)$ e $\lim_{sup}(d_k)$ são, respectivamente, os limites inferior e superior da classe d_k em HU.

A partir da Equação 3.1, o percentual P_k da classe d_k é dado por:

$$P_k(x, y) = \frac{f_k(x, y)}{\sum_{k=0}^5 f_k(x, y)}. \quad (3.3)$$

O percentual da classe 6 não é calculado porque a mesma não está classificada.

A forma inicial para o método *level set* é um círculo de raio $r = 0,5$ cm dentro da região do AVCh. Este valor de raio foi utilizado pois a menor área de AVCh desta base é de $1,10 \text{ cm}^2$. O método proposto determina o centro (x_{init}, y_{init}) do círculo como:

$$x_{init} = \frac{\sum_{i=1}^m x_i}{m}, \quad (3.4)$$

e

$$y_{init} = \frac{\sum_{i=1}^m y_i}{m}, \quad (3.5)$$

em que m é o número de *voxels* com $P_0 < 0,5$, e apenas os *voxels* que seguem esta regra são utilizados no cálculo. O limiar, utilizado no percentual das classes, foi escolhido empiricamente.

Na Figura 11, da esquerda para a direita, são ilustrados três exemplos dos passos de

¹**voxel:** representa a unidade de volume da imagem, considerando a espessura do corte. A espessura do corte forma a terceira dimensão e está relacionada à profundidade do corte.

iniciação: (a) o crânio segmentado; (b) análise das densidades UH; (c) crânio segmentado com os *pixels* que seguem a regra $P_0 < 0,5$ destacados em vermelho.




Figura 11: Da esquerda para direita, três exemplos da etapa de iniciação em que o *level set* zero é determinado pela análise das densidades radiológicas cerebral: a) crânio segmentado; b) análise das densidades UH do crânio (fluido espinhal em magenta, massa branca em verde, massa cinzenta em azul, sangue em vermelho); e c) *pixels* que seguem a regra $P_0 < 0,5$ destacados em vermelho dentro do crânio.

3.2 Algoritmo Parzen *level set*

Após a detecção do AVCh, a segunda proposta deste trabalho é a utilização do método *level set* utilizando uma estimação não paramétrica com base na Janela de Parzen. Neste trabalho, a Janela de Parzen adota uma matriz de covariância diagonal n -dimensional, $\Lambda = \sigma^2 I_d$, em que I é uma matriz identidade. Assume-se também que as características individuais são mutualmente descorrelacionadas e possuem a mesma variância σ^2 . Para $d = 3$, a matriz diagonal

$$\Lambda = \sigma^2 I_d = \begin{bmatrix} \sigma^2 & 0 & 0 \\ 0 & \sigma^2 & 0 \\ 0 & 0 & \sigma^2 \end{bmatrix}.$$

Então a $p(z)$ final, da Equação 2.19, utilizando o *kernel* da Equação 2.20 pode ser expressa como (BISHOP, 2006)

$$p(z) = \frac{1}{k} \sum_{i=1}^k \frac{1}{(2\pi)^{d/2} h^d} \exp\left(-\frac{1}{2h^2} \|z_i - z\|^2\right), \quad (3.6)$$

em que h representa o desvio padrão σ das componentes Gaussianas e $\|\cdot\|^2$ representa a distância Euclidiana. Neste trabalho foi utilizado o valor de $h = 7$, em que o mesmo foi obtido empiricamente. Na Figura 12 é apresentado um exemplo de uma estimativa da distribuição de probabilidade espacial utilizando FDP da Janela de Parzen de uma imagem de TC do crânio.




Figura 12: Exemplo da estimação da FDP da Janela de Parzen: a) região do crânio; b) estimação da distribuição de probabilidade espacial.

Para um método *level set* com duas fases, isto é, para a binarização de uma imagem, a solução geral da velocidade de propagação F_{prop} , da Equação 2.7 é dada por

$$F_{prop} = F_1(\vec{\eta}) + F_2(-\vec{\eta}), \quad (3.7)$$

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

Na abordagem proposta, é utilizado um modelo de verossimilhança (MITICHE; AYED, 2010) para computar o termo de propagação F_{prop} em que as componentes F_1 e F_2 são estimadas por meio da Janela de Parzen. Para obter essas componentes são extraídos

dois conjuntos de *pixels*², sendo um deles pertencente à região interna da curva, dado por $Z_1 = \{z_i\}_{i=1}^n$ e o outro conjunto pertencente à região externa da curva, dado por $Z_2 = \{z_i\}_{i=1}^n$, em que n é a quantidade de *pixels*. Para gerar Z_1 e Z_2 os *pixels* são obtidos aleatoriamente dentro de suas respectivas regiões. Os *pixels* desses dois conjuntos formam duas janelas de tamanho $h \times h$ utilizadas no método de Parzen. Cada *pixel* das regiões Z_1 e Z_2 é um vetor de 3 atributos, a saber, intensidade do pixel I , média μ e variância σ^2 .

Finalmente, a velocidade de propagação de verossimilhança baseada na estimativa de Parzen, é definida como:

$$F_{prop} = p(I, \mu_1, \sigma_1^2) \vec{\eta} - p(I, \mu_2, \sigma_2^2) \vec{\eta}, \quad (3.8)$$

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

Neste trabalho foi utilizado o método *level set* proposto por Braga (2016) que utiliza filtros da mediana e operadores de morfologia matemática detalhada na Seção 2.2.4.3. Este algoritmo *level set* utiliza o filtro da mediana, que consiste de um filtro não paramétrico, para regularizar a curva ao invés de utilizar a curvatura $\mathcal{K}$ apresentada na Equação 2.8.

Para apresentar a evolução da abordagem proposta, a Figura 13a apresenta o contorno inicial (*level set zero*) que foi obtido baseado na análise das densidades radiológicas do crânio explicada na Seção 3.1, enquanto as Figuras 13b-13e ilustram o processo de evolução do contorno desde sua iniciação até a segmentação final, apresentada na Figura 13f.

²cada *pixel* z da imagem é definido como um vetor de dimensão d .




Figura 13: Segmentação obtida pela abordagem proposta com a iniciação baseada na análise das densidades radiológicas do cérebro: a) iniciação contorno ativo; b) - e) evolução do processo de segmentação; e f) resultado final da segmentação.

3.3 Conclusão do capítulo

Neste capítulo foi proposto uma análise das densidades radiológicas do crânio, a fim de automatizar a iniciação do método *level set*. Em seguida, foi apresentada a principal contribuição desta dissertação, que consiste em calcular a função de densidade de probabilidade do *level set* rápido utilizando a Janela de Parzen para segmentação de AVCh em imagens de TC do crânio. Sendo assim, as etapas da abordagem proposta foram apresentadas e as contribuições detalhadas.

O próximo capítulo apresenta as métricas de avaliação adotadas nesta dissertação, em que os resultados obtidos por um médico especialista são tomados como referência para cálculo e avaliação das mesmas.

MÉTRICAS UTILIZADAS PARA AVALIAÇÃO DOS RESULTADOS DE SEGMENTAÇÃO

Com o intuito de fornecer uma avaliação quantitativa do resultado da segmentação do AVC hemorrágico, assim como em Bhadauria, Singh e Dewal (2013) e Bhadauria e Dewal (2014), utilizamos métricas comumente adotadas na literatura para avaliar métodos de segmentação. Tais métricas mensuram a discrepância e/ou semelhança entre a região segmentada e a região da imagem de referência. A região de referência, AVCh, é delineada manualmente por um médico especialista e tomada como padrão ouro (*ground truth*). A avaliação é realizada usando métricas com base na quantidade de *pixels* que tenham sido correctamente e/ou incorrectamente atribuídos a uma região da imagem (GARCIA; DOMINGUEZ; MEDEROS, 2015).

Em uma imagem com apenas duas regiões, a segmentação pode ser vista como um processo de classificação (PONT-TUSET; MARQUES, 2013) no qual cada *pixel* é rotulado como 0 ou 1, em que 1 significa que o *pixel* pertence à região de interesse (*ROI*), que neste trabalho é o AVCh, e 0 significa a região de fundo (*RF*). A região alvo representa a área de interesse que é nomeada como classe positiva, enquanto que a região do fundo é chamada classe negativa.

Para o resultado de um processo de segmentação, espera-se que uma região segmentada (*RS*) por um método computacional seja o mais semelhante possível à *ROI*. A relação entre estas duas regiões pode ser expressa em uma matriz de confusão, como mostra na Tabela 1, em que todas essas medidas estão em função das medidas de verdadeiro positivo (*VP*), falso positivo (*FP*), verdadeiro negativo (*VN*) e falso negativo (*FN*) (METZ, 1978).

A Figura 14 ilustra a representação gráfica de *VP*, *FP*, *VN* e *FN*, em que a imagem de fundo é composta por $VN + FP$ e a região de interesse é a soma de $VP + FN$, em que:

- *VP* é igual ao número de *pixels* que aparece tanto na área do AVCh segmentado

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

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

manualmente como na área hemorrágica segmentada pelo método computacional.

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




Figura 14: Regiões onde VP , FP , VN e FN são computadas. O círculo ROI representa a região de referência (padrão ouro). O círculo RS representa a região segmentada por um método computacional (Adaptado de Garcia, Dominguez e Mederos (2015)).

4.1 Acurácia

A medida de acurácia significa a proporção de *pixels* de AVCh segmentados corretamente por todos os *pixels* da imagem do AVCh. Seguindo a notação da Tabela 1, a métrica de acurácia (ACC) é definida como (BHADAURIA; SINGH; DEWAL, 2013):

$$ACC = \frac{VP + VN}{VP + VN + FP + FN}. \quad (4.1)$$

4.2 Precisão, Sensitividade e Especificidade

A precisão (PRE) mede a proporção de verdadeiros positivos em relação a todas as predições positivas. Esta medida é altamente suscetível a desbalanceamentos do conjunto de dados. Esta métrica é determinada por (BHADARIA; DEWAL, 2014):

$$PRE = \frac{VP}{VP + FP}. \quad (4.2)$$

A sensibilidade (SEN) de um método reflete o quanto este é eficaz em identificar corretamente, dentre todos os *pixels* avaliados, aqueles que realmente apresentam a característica de interesse, sendo calculada por (BHADARIA; DEWAL, 2014):

$$SEN = \frac{VP}{VP + FN}. \quad (4.3)$$

A especificidade (SPC) de um método reflete o quanto ele é eficaz em identificar corretamente os *pixels* que não apresentam a condição de interesse, ou seja, significa a porcentagem de *pixels* devidamente excluídos nos resultados de segmentação em relação a todos os *pixels* que não é AVCh, sendo calculada por (BHADARIA; DEWAL, 2014):

$$SPC = \frac{VN}{VN + FP}. \quad (4.4)$$

4.3 Coeficiente de Correlação de Matthew

O coeficiente de correlação de Matthew (MCC) foi introduzido pela primeira vez por Matthews (1975). A medida é definida no intervalo $[-1,1]$, em que os limites representam a classificação incorreta e a classificação correta, respectivamente.

No caso de duas classes (P: positivos, N: negativos), a matriz de confusão é $\begin{pmatrix} VP & FN \\ FP & VN \end{pmatrix}$, em que V e F representam respectivamente verdadeiro e falso. O Coeficiente de Correlação de Matthews é definido como (MATTHEWS, 1975; BALDI *et al.*, 2000):

$$MCC = \frac{VP \times VN - FP \times FN}{\sqrt{(VP + FP)(VP + FN)(VN + FP)(VN + FN)}}. \quad (4.5)$$

Como a detecção do AVC é um problema desbalanceado, ou seja, há mais *pixels* para classificar como fundo do que AVC. A métrica MCC calcula a correlação de predição, independentemente do tamanho das regiões, assim, essa métrica torna-se relevante neste estudo.

4.4 Índice Jaccard

O índice de Jaccard (Jac) é uma medida estatística de similaridade entre conjuntos de amostras. Para dois conjuntos de dados, esta métrica é definida como a cardinalidade de sua intersecção dividida pela cardinalidade da soma entre os resultados da segmentação computadorizada e o padrão ouro (QIAN *et al.*, 2013).

$$Jac = \frac{\#\{ROI \cap RS\}}{\#\{ROI\} + \#\{RS\}} = \frac{VP}{VP + FP + FN}, \quad (4.6)$$

em que *ROI* representa a região segmentada manualmente (ground truth), e *RS* a região segmentada por um algoritmo, e $\#\{\cdot\}$ significa o número de pixels de uma região.

4.5 Coeficiente Dice

O Coeficiente de Dice é utilizado para mensurar a semelhança entre regiões segmentadas automaticamente e manualmente, sendo definido como

$$Dice = 2 \cdot \frac{\#\{ROI \cap RS\}}{\#\{ROI\} + \#\{RS\}} = \frac{2VP}{2VP + FP + FN}, \quad (4.7)$$

em que *ROI* representa a região segmentada manualmente (ground truth), e *RS* a região segmentada por um algoritmo, e $\#\{\cdot\}$ denota o número de pixels de uma região. O valor da sobreposição dos intervalos com taxa igual a 0, caracteriza uma não sobreposição entre as duas regiões, enquanto que, quando igual 1, caracteriza uma sobreposição perfeita (DICE, 1945).

4.6 Conclusão do capítulo

Neste capítulo são apresentadas as métricas de avaliação adotadas nesta dissertação, em que os resultados obtidos por um médico especialista são tomados como referência para cálculo e

avaliação das mesmas.

O próximo capítulo apresenta os resultados experimentais desta dissertação, além de uma análise comparativa entre a abordagem proposta e outros métodos de segmentação de AVCh em imagens do crânio existentes na literatura.

EXPERIMENTOS E RESULTADOS

Este capítulo apresenta os resultados experimentais obtidos pela abordagem proposta $LSDRC_{parzen}$ apresentada no Capítulo 3 em comparação com outros cinco métodos comumente utilizados na literatura para segmentação de imagens médicas (WANG; BU, 2010; BHADARIA; SINGH; DEWAL, 2013; BHADARIA *et al.*, 2015; BEUCHER; LANTUÉJOUL, 1979; WANG; FRIMMEL; SMEDBY, 2014). Para a análise dos resultados utilizamos 100 imagens de Tomografia Computadorizada do crânio, em que o AVCh foi previamente segmentado por um médico especialista parceiro deste projeto. Os resultados obtidos estão divididos em duas etapas: análise do algoritmo de iniciação proposto e análise da segmentação do AVC hemorrágico. Todos os experimentos foram realizados em um processador Intel Core i5 com 3.2 GHz, 8 Gb RAM e sistema operacional Mac OS X El Capitan 10.11.6, usando a linguagem MATLAB R2014b (64-bit).

5.1 Aquisição de imagens

As imagens de TC do crânio utilizadas neste trabalho foram adquiridas em parceria com o Hospital do Coração de Fortaleza, Brasil. Utilizou-se um tomógrafo GE MEDICAL SYSTEM modelo Optima CT660 para a aquisição destas imagens. Os planos tomográficos foram definidos com base no plano axial, nas seguintes condições: espessura de corte de 0,7 mm, campo de visão de 230 mm, voltagem do tubo de 120 Kv, corrente elétrica do tubo de 80 mA, a dimensão da imagem reconstruída é de 512 x 512 *pixels* e *voxel* com dimensões 0,488 x 0,488 x 1,5 mm. As imagens são quantificadas em 16 *bits* e armazenadas no padrão DICOM (Digital Imaging and Communications in Medicine). Nestes exames de TC a área afetada pelo AVCh varia entre 1,1 cm² e 15,07 cm², além de incluir regiões de formas diversas. Essas imagens de AVC hemorrágico e suas respectivas segmentações obtidas por um médico especialista serão disponibilizados on-line juntamente com todos os resultados obtidos neste estudo.

5.2 Análise do algoritmo de iniciação

Na análise do algoritmo de iniciação é avaliado o êxito do método na iniciação do *level set* zero dentro da área do AVCh na imagem de TC do crânio. Logo, a iniciação é dita satisfatória quando o *level set* zero é iniciado dentro da região de interesse.

Nesta seção são comparadas a iniciação proposta neste trabalho e a utilizando *Fuzzy C-means* (BHADARIA; SINGH; DEWAL, 2013). A Figura 15 apresenta exemplos de inicializações dos métodos avaliados.




Figura 15: Resultados da iniciação da abordagem proposta em comparação com o método *Fuzzy C-means*. a) imagem original; b) iniciação da abordagem proposta; c) iniciação utilizando *Fuzzy C-means*.

Os resultados obtidos com a abordagem proposta de iniciação são considerados satisfatórios, visto que todas as curvas são inicializadas dentro do AVCh, obtendo 100% de acerto. Já a iniciação proposta por Bhaduria, Singh e Dewal (2013) utilizando a iniciação com a abordagem *Fuzzy C-means* (FCM) obteve 97% de acerto.

As três imagens que não obtiveram êxito pelo método FCM possuem área 1,10, 1,43 e 1,79 cm^2 . A menor área que o método proposto por Bhaduria, Singh e Dewal (2013) obteve êxito na iniciação foi 1,93 cm^2 , o que nos faz concluir que regiões menores que 1,9 cm^2 podem conter erros na iniciação pela abordagem já existente na literatura. Vale ressaltar que o método $LSDRC_{parzen}$ proposto neste trabalho, obteve êxito em todas as iniciações, independente da área da região afetada pelo AVCh.

5.3 Análise dos métodos de segmentação de AVCh em imagens de TC do crânio

Os resultados obtidos pelo método proposto são comparados com outros existentes na literatura utilizando a segmentação obtida por um médico especialista como referência da região a ser segmentada.

O método proposto é comparado com métodos de iniciação automática, e outros com iniciação manual. Os métodos aplicados na segmentação do AVC hemorrágico, utilizando iniciação manual são Crescimento de Região (CR), Watershed (WS), Level Set com base no Método De Propagação Coerente (LSCPM) e Algoritmo de Agrupamento *Fuzzy C-means* (FCM). A Figura 16 apresenta 4 exemplos de segmentação do AVCh em imagens de TC do crânio por cada um dos métodos de iniciação manual citados.

Já os resultados obtidos pelos métodos de segmentação de iniciação automática são apresentados na Figura 17, são eles o método proposto *level set* baseado nas densidades radiológicas do cérebro combinado com a Janela de Parzen ($LSDR_{C_{parzen}}$) e o Algoritmo de *level set* com *Fuzzy C-means* ($LSFCM_{evol}$). Para verificar a eficiência das abordagens propostas separadamente, tanto da iniciação quanto do uso da FDP baseado na Janela de Parzen para a propagação da curva do *level set*, mais dois experimentos de segmentação do AVCh em imagens de TC do crânio são apresentados. Esses dois experimentos são realizados, um utilizando a iniciação proposta neste trabalho com a evolução do *level set* proposta em Li *et al.* (2008) denominado ($LSDR_{C_{evol}}$) e o outro a combinação da estimação da FDP pela Janela de Parzen proposta neste trabalho com a iniciação proposta em Bhadauria, Singh e Dewal (2013) denominado ($LSFCM_{parzen}$).

Os resultados da segmentação de toda a base de imagens utilizando os métodos citados, são apresentados na Tabela 2. As métricas aqui mostradas são: acurácia (ACC), Precisão (PRE), Sensitividade (SEN) e Especificidade (SPC).

Os resultados apresentados na Tabela 2, mostram que o método proposto obteve a maior média de acurácia com 99,84% e menor desvio padrão com 0,08%, demonstrando que o método proposto é superior aos demais neste quesito. Estes resultados podem ser confirmados pelos altos índices de precisão, sensibilidade e especificidade.

Entretanto, vale ressaltar que apenas o método Crescimento de Região não obteve acurácia acima de 99%, porém obteve taxa de acurácia de 98,67%. Esta análise pode ser replicada para as demais métricas precisão, sensibilidade e sensibilidade para todos os métodos, visto que os resultados da maioria são superiores a 99%. Esta análise sugere que estas métricas, embora




Figura 16: Exemplos de segmentação do AVCh em imagens de TC do crânio obtidos por métodos de iniciação manual, sendo: a) em branco, padrão ouro obtido pelo médico especialista; b) em azul, método LSCPM; c) em rosa, método FCM; d) em verde, método WS e e) em amarelo, método CR.




Figura 17: Exemplos de segmentação de AVCh obtidos por métodos de segmentação automática em imagens de TC do crânio, sendo: a) em branco, padrão ouro obtido por médico especialista; b) em vermelho, abordagem proposta, $LSDRC_{parzen}$; c) em ciano, método $LSDRC_{evol}$; d) em magenta, método $LSFCM_{parzen}$; e e) em laranja, método $LSFCM_{evol}$.

Tabela 2: Avaliação da segmentação do AVC hemorrágico através dos métodos CR, WS, LSCPM, FCM, $LSDRC_{parzen}$, $LSFCM_{parzen}$, $LSDRC_{evol}$ e $LSFCM_{evol}$ pelas métricas acurácia (ACC), Precisão (PRE), Sensitividade (SEN) e Especificidade (SPC).

Iniciação	Algoritmo	ACC(%)	PRE(%)	SEN(%)	SPC(%)
Automático	$LSDRC_{parzen}$	99,84 ± 00,08	99,98 ± 00,02	99,86 ± 00,09	97,82 ± 02,33
	$LSFCM_{parzen}$	99,39 ± 02,48	99,51 ± 02,50	99,86 ± 00,09	93,59 ± 17,10
	$LSDRC_{evol}$	99,79 ± 00,13	99,97 ± 00,03	99,81 ± 00,13	97,42 ± 02,23
	$LSFCM_{evol}$	99,19 ± 02,97	99,33 ± 02,98	99,86 ± 00,10	90,60 ± 21,10
Manual	CR	98,67 ± 04,28	99,00 ± 04,36	99,66 ± 00,23	92,84 ± 21,88
	WS	99,69 ± 00,22	99,84 ± 00,19	99,85 ± 00,11	87,32 ± 13,38
	LSCPM	99,72 ± 00,23	99,75 ± 00,25	99,96 ± 00,05	83,03 ± 11,13
	FCM	99,19 ± 02,97	99,32 ± 02,99	99,86 ± 00,10	90,53 ± 21,31

muito usadas na literatura, não caracterizam bem pequenas diferenças nos resultados obtidos na segmentação de AVCh em imagens de TC do crânio. Isto pode ser atribuído ao fato de que a região com AVCh é bem menor que a área total do cérebro. Por exemplo, a acurácia relaciona a quantidade de *pixels* segmentados corretamente com o total, e como o AVCh é uma região bem menor que a a região "não AVCh", então mesmo que o AVCh seja completamente perdido, a acurácia continuará elevada.

Deste modo, faz-se necessário analisar os resultados da segmentação do AVCh utilizando métricas que priorizem a região de interesse, as quais são apresentadas na Tabela 3. Estas métricas são: Coeficiente de Correlação de Matthew (MCC), Índice Jaccard (Jac) e Dice aplicadas aos resultados obtidos na segmentação de toda a base de 100 imagens.

Tabela 3: Avaliação da segmentação do AVC hemorrágico através dos métodos CR, WS, LSCPM, FCM, $LSDRC_{parzen}$, $LSFCM_{parzen}$, $LSDRC_{evol}$ e $LSFCM_{evol}$ pelas métricas Coeficiente de Correlação de Matthew (MCC), Índice Jaccard (Jac) e Dice.

Iniciação	Algoritmo	MCC(%)	Jac(%)	Dice(%)
Automático	$LSDRC_{parzen}$	92,56 ± 02,45	86,10 ± 05,99	92,41 ± 02,84
	$LSFCM_{parzen}$	90,53 ± 14,10	84,32 ± 15,50	90,18 ± 15,74
	$LSDRC_{evol}$	88,05 ± 12,06	79,45 ± 16,00	87,31 ± 14,10
	$LSFCM_{evol}$	87,70 ± 16,88	80,33 ± 19,27	87,14 ± 18,47
Manual	CR	80,58 ± 16,90	68,23 ± 17,20	79,26 ± 18,30
	WS	86,87 ± 07,41	77,17 ± 11,20	86,63 ± 07,84
	LSCPM	89,27 ± 05,78	80,50 ± 09,79	88,85 ± 06,51
	FCM	88,00 ± 16,80	80,77 ± 19,20	87,41 ± 18,50

Analisando os resultados apresentados na Tabela 3, constata-se que o método proposto $LSDRC_{parzen}$ também obteve os melhores resultados nestas novas métricas analisadas.

Analisando o MCC, o resultado obtido por $LSDRC_{parzen}$ é 2% maior que a segunda melhor abordagem $LSFCM_{parzen}$, que também utiliza a abordagem de estimação da Janela de Parzen para calcular os parâmetros que controlam a evolução do *level set* proposta neste trabalho, além de ser 4,5% superior ao $LSDRC_{evol}$ e 3,2% superior que o melhor método manual $LSCPM$. Este experimento foi feito para testar a eficiência das abordagens propostas. Esta superioridade indica que a abordagem $LSDRC_{parzen}$ proposta neste trabalho proporciona uma melhor predição dos locais afetados por AVCh.

Analisando os resultados obtidos pelas métricas Jaccard e Dice, observa-se que os valores obtidos pelo método proposto $LSDRC_{parzen}$ possui os melhores resultados com $86,10 \pm 5,99$ e $92,41 \pm 2,84$, respectivamente, sendo 2% maior que a segunda melhor abordagem $LSFCM_{parzen}$ nas duas métricas, que também utiliza a estimação da Janela de Parzen para expandir o contorno. Considerando o índice de Jaccard e Dice, o método proposto $LSFCM_{parzen}$ é no mínimo 5% superior aos demais métodos que não usam a proposta da Janela de Parzen, demonstrando que a região segmentada por este método possui uma maior similaridade com a segmentação obtida pelo médico especialista.

Para uma melhor análise dos valores obtidos pelos métodos de segmentação de AVC, a Figura 18 apresenta o diagrama de caixas das métricas Coeficiente de Correlação de Matthew (MCC), Índice Jaccard e DICE.

Analisando o diagrama de caixas do método proposto, em vermelho, em relação aos demais apresentados na Figura 18, percebe-se que os resultados obtidos pelos métodos que utilizam a estimação baseada na Janela de Parzen para segmentação do AVCh possuem baixa dispersão dos dados, sendo superior a abordagem que utiliza a iniciação proposta. Deste modo, podemos assumir que o método proposto, além de possuir os melhores resultados independente da métrica de avaliação de segmentação, possuem uma maior similaridade com o padrão ouro.

A Figura 19 apresenta um exemplo da análise qualitativa de uma segmentação do AVCh em imagem de TC do crânio, em que os verdadeiro positivos são apresentados em verde, os falso positivos em vermelho, os falso negativos em azul e os verdadeiro negativos apresentados em tom de cinza da imagem original.

Analisando a Figura 19, percebe-se que todos os métodos possuem a região verde similar, entretanto a distribuição das demais cores variam devido a supersegmentação ou subsegmentação. No caso da supersegmentação, que é caracterizada pela cor vermelha, apresentada de forma intensa pelos métodos $LSCPM$ e WS , nota-se que estes métodos segmentaram a vizinhança do AVCh como integrante do AVCh. Já os métodos que apresentam subsegmentação detectam apenas parte do AVCh, que caracteriza-se pela presença da cor azul,




Figura 18: Boxplot do desempenho dos métodos de segmentação do AVCh em imagens de TC do crânio utilizando as métricas Coeficiente de Correlação de Matthew (MCC), Índice Jaccard e DICE. A abordagem proposta neste trabalho é apresentada em vermelho.

como é o caso do CR. Os métodos com iniciação automática possuem pequenas falhas na periferia do AVCh, identificando parte da vizinhança do AVCh como AVCh, e/ou deixando de reconhecer partes do mesmo. Nesta análise, os métodos com a abordagem da Janela de Parzen possuem poucas regiões com falhas, predominando a cor verde na análise.

Um segundo exemplo é apresentado na Figura 20, em que a diferença entre a região do AVCh segmentada pelo médico especialista e a região obtida pelos métodos computacionais




Figura 19: As regiões de segmentação do AVC obtidas pelos métodos em comparação, adotando o verde para os verdadeiros positivos, o vermelho para o falso positivo e o azul para o falso negativo: a) Imagem Original; b) LSDRC_{parzen}; c) LSFCM_{parzen}; d) LSDRC_{evol}; e) LSFCM_{evol}; f) LSCPM; g) FCM; h) WS; i) CR.

é apresentada em vermelho, seja por sobre ou subsegmentação. Percebe-se na análise deste exemplo, que o método proposto $LSDRC_{parzen}$ apresenta uma área vermelha menor que os demais métodos, caracterizando poucas falhas.

Uma última análise quanto à qualidade da segmentação obtida pelos métodos é necessária, visto que algumas imagens apresentam regiões pequenas de AVCh, conforme foi discutido na Seção 5.2. Neste sentido, a Figura 21 apresenta a segmentação obtida pelos métodos avaliados em uma amostra de $1,43 \text{ cm}^2$.

Percebe-se que dos métodos que utilizam a iniciação manual, apenas o LSCPM e Watershed possuem bons resultados, entretanto o *Fuzzy C-means* (FCM) e crescimento de região apresentam sobresegmentação, reconhecendo partes que não integram o AVCh como sendo parte do AVCh. Já os métodos automáticos possuem resultados satisfatórios apenas quando utilizam a iniciação proposta, pois como visto na Seção 5.2, o método de iniciação utilizando *Fuzzy C-means* não obtém resultados satisfatórios, o que causa erro de sobresegmentação, já que o *level set* zero foi iniciado errôneamente.

Por fim, faz-se necessário avaliar os métodos quanto ao tempo gasto na segmentação, desde a iniciação dos métodos até a obtenção da região segmentada, sendo esta análise apresentada na Tabela 4.

Tabela 4: Tempos de segmentação do AVC hemorrágico pelos métodos $LSDRC_{parzen}$, $LSFCM_{parzen}$, $LSDRC_{evol}$, $LSFCM_{evol}$, CR, WS, LSCPM e FCM.

Abordagem	Algoritmo	$tempo(s)$
Automático	$LSDRC_{parzen}$	$2,29 \pm 1,81$
	$LSFCM_{parzen}$	$11,83 \pm 6,72$
	$LSDRC_{evol}$	$25,42 \pm 0,98$
	$LSFCM_{evol}$	$34,01 \pm 3,39$
Manual	CR	$3,10 \pm 1,70$
	WS	$4,80 \pm 0,62$
	LSCPM	$1,76 \pm 0,29$
	FCM	$8,69 \pm 3,16$

Analisando as médias de tempo de segmentação, constata-se que o Algoritmo de *Level Set* com base no Método de Propagação Coerente (LSCPM) possui o menor tempo com $1,76 \pm 0,29$ segundos, sendo seguido pelo método proposto $LSDRC_{parzen}$ com $2,29 \pm 1,81$. Os métodos manuais Crescimento de Região e Watershed vêm em seguida com $3,10 \pm 1,70$ e $4,80 \pm 0,62$, respectivamente. Os demais métodos automáticos possuem um desempenho inferior, obtendo tempos de segmentação superiores à 11 segundos. A Figura 22 apresenta a dispersão dos tempos obtidos por todas as amostras.




Figura 20: Diferença entre a segmentação do especialista e os métodos avaliados. a) Imagem Original; b) LSDRC_{parzen}; c) LSFCM_{parzen}; d) LSDRC_{evol}; e) LSFCM_{evol}; f) LSCPM; g) FCM; h) WS; i) CR.






Figura 21: Resultados dos métodos de segmentação em imagens que contém áreas pequenas de AVCh. a) Imagem Original; b) LSDRC_{parzen}; c) LSFCM_{parzen}; d) LSDRC_{evol}; e) LSFCM_{evol}; f) LSCPM; g) FCM; h) WS; i) CR.



(a)



(b)

Figura 22: Gráfico de tempo dos métodos avaliados na segmentação do AVCh em imagens de TC do crânio: a) tempo de 0-40s e b) tempo de 0-8s.

Percebe-se pela dispersão dos tempos na Figura 22, que o método proposto $LSDRC_{parzen}$ possui o tempo menor que o LSCPM em algumas amostras, mas em média o LSCPM mantém superioridade.

5.4 Conclusão do capítulo

Este capítulo apresentou os experimentos realizados em um banco de com 100 imagens de pacientes com AVC hemorrágico, em que o objetivo é realizar a segmentação da região afetada, utilizando o padrão ouro obtido por um médico especialista como referência. Diversas métricas foram utilizadas para avaliar a qualidade dos resultados obtidos na segmentação AVCh, entretanto o método automático de segmentação proposto neste trabalho apresentou-se superior em todas as métricas de qualidade de segmentação. Quanto ao tempo de segmentação, o algoritmo de segmentação mais rápido dentre os avaliados é o Algoritmo de *Level Set* com base no Método de Propagação Coerente (LSCPM), seguido pelo método proposto $LSDRC_{parzen}$ com $2,29 \pm 1,81$. Sendo assim, podemos dizer que o método proposto apresenta o melhor custo benefício dentre os métodos avaliados.

CONCLUSÃO E TRABALHOS FUTUROS

Este capítulo apresenta as conclusões desta dissertação, alcançadas a partir dos objetivos apontados, da análise e avaliações dos resultados obtidos. Além disso, são apresentadas as perspectivas de trabalhos.

Neste trabalho é proposto um algoritmo *level set* utilizando uma abordagem de estimação não paramétrica baseada na Janela de Parzen, denominado de $LSDRC_{parzen}$, para a segmentação de Acidente Vascular Cerebral do tipo hemorrágico em imagens TC do crânio.

A primeira contribuição deste estudo é a construção de um banco de imagens junto a um médico especialista, o que inclui as imagens de TC e o padrão ouro da segmentação à ser disponibilizado via publicação acadêmica.

A segunda contribuição apresentada nesta dissertação consiste em iniciar de forma automática o método *level set* dentro da região de AVCh com base nas densidades radiológicas do cérebro. O método de iniciação proposto é avaliado juntamente com outro existente na literatura. Os resultados desta iniciação mostram que o método proposto obteve êxito em todas as imagens analisadas, o que não ocorreu com o método utilizando FCM, pois o mesmo apresentou problemas na segmentação de regiões pequenas, o que não é uma limitação da abordagem proposta neste trabalho. Portanto, a utilização da iniciação abordada foi eficaz na identificação da região interna do AVCh em todas as imagens analisadas, independente do tamanho, forma ou posição do mesmo.

A terceira proposta desta dissertação é o uso de uma estimação não paramétrica da FDP com base na Janela de Parzen na função de propagação no *level set* proposto por Braga (2016). A abordagem proposta foi comparada com outras existentes na literatura sobre segmentação de AVCh em imagens de TC do crânio, utilizando como referência a segmentação obtida por um médico especialista. Para esta análise foram utilizadas métricas que analisavam a imagem inteira no cálculo e outras que analisavam apenas a região de interesse segmentada. Em ambas as análises, o método *level set* proposto com base nas densidades radiológicas do cérebro combinado com a Janela de Parzen obteve melhores resultados, entretanto a diferença para os demais métodos é mais significativa quando as métricas utilizadas dão ênfase ao AVCh em

detrimento das demais estruturas da imagem de TC do crânio.

O método proposto alcançou resultados promissores quanto aos objetivos deste trabalho, além de construir um método competitivo em relação aos demais avaliados, considerando-se a qualidade e o tempo. Os resultados mostram que o método proposto pode integrar sistemas de auxílio ao diagnóstico médico na área de radiologia na segmentação de AVCh em imagens de TC do crânio.

Este trabalho irá disponibilizar o banco de imagens e os métodos computacionais à comunidade científica, com o intuito que nossos resultados possam ser reproduzidos e novos métodos propostos.

Considerando o que foi realizado e avaliado, as sugestões para trabalhos futuros são:

- avaliar o método proposto em outras aplicações para auxílio ao diagnóstico médico em outras áreas;
- generalizar a abordagem proposta para três dimensões, o que irá possibilitar a análise o exame completo do paciente, não apenas imagens individuais;
- avaliar novos métodos de aprendizado de máquina para estimação da função de densidade de probabilidade do método *level set*.

Referências

ADAMS, Harold; ADAMS, Robert; ZOPPO, Gregory Del; GOLDSTEIN, Larry B. Guidelines for the early management of patients with ischemic stroke 2005 guidelines update a scientific statement from the stroke council of the american heart association/american stroke association. **Stroke**, American Heart Association, v. 36, n. 4, p. 916–923, 2005.

AICHA, Belgherbi; ABDELHAFID, Bessaid. Morphological segmentation of the spleen from abdominal CT images. **International Journal of Image, Graphics and Signal Processing**, Modern Education and Computer Science Press, v. 4, n. 4, p. 56, 2012.

AL-FARIS, Ali Qusay; NGAH, Umi Kalthum; ISA, Nor Ashidi Mat; SHUAIB, Ibrahim Lutfi. Breast MRI tumour segmentation using modified automatic seeded region growing based on particle swarm optimization image clustering. In: **Soft Computing in Industrial Applications**. Cham: Springer International Publishing, 2014. p. 49–60. ISBN 978-3-319-00930-8.

ALBUQUERQUE, Victor Hugo C de; Rebouças Filho, PP; CAVALCANTE, Tarique S; TAVARES, João Manuel RS. New computational solution to quantify synthetic material porosity from optical microscopic images. **Journal of Microscopy**, Wiley Online Library, v. 240, n. 1, p. 50–59, 2010.

AMERICAN HEART ASSOCIATION AND AMERICAN STROKE ASSOCIATION. **What are the types of stroke?** 4 2016. http://www.strokeassociation.org/STROKEORG/AboutStroke/About-Stroke_UCM_308529_SubHomePage.jsp. Acessado em: 26 de janeiro de 2016.

ARAUJO, Alex Fernando de. **Método para extração e caracterização de lesões de pele usando difusão anisotrópica, crescimento de regiões, watersheds e contornos ativos**. Dissertação (Mestrado) — Universidade Estadual Paulista, Instituto de Biociências, Letras e Ciências Exatas, Pós-graduação em Ciência da Computação, 2010.

BALDI, Pierre; BRUNAK, Søren; CHAUVIN, Yves; ANDERSEN, Claus AF; NIELSEN, Henrik. Assessing the accuracy of prediction algorithms for classification: an overview. **Bioinformatics**, Oxford Univ Press, v. 16, n. 5, p. 412–424, 2000.

BARBEDO, Jayme Garcia Arnal; KOENIGKAN, Luciano Vieira; SANTOS, Thiago Teixeira. Identifying multiple plant diseases using digital image processing. **Biosystems Engineering**, Elsevier, v. 147, p. 104–116, 2016.

BENSON, C. C.; LAJISH, V. L.; RAJAMANI, Kumar. Brain Tumor Extraction from MRI Brain Images Using Marker Based Watershed Algorithm. In: SCMS Sch of Engn & Technol; IEEE Commun Soc; IEEE SMC; acm. **International Conference On Advances In Computing, Communications And Informatics (ICACCI)**. Kochi, India, 2015. p. 318–323. ISBN 978-1-4799-8792-4.

BEUCHER, S.; LANTUÉJOUL, C. Use of watersheds in contour detection. In: SOCIETÀ ASTRONÓMICA ITALIANA. **International Conference on Image Processing**. Rennes, França, 1979. p. 1–10.

BEZDEK, James C. **Pattern recognition with fuzzy objective function algorithms**. Norwell, MA, USA: Kluwer Academic Publishers, 1981. ISBN 0306406713.

BHADAURIA, HS; DEWAL, ML. Intracranial hemorrhage detection using spatial fuzzy c-mean and region-based active contour on brain CT imaging. **Signal, Image and Video Processing**, Springer, v. 8, n. 2, p. 357–364, 2014.

BHADAURIA, HS; SINGH, Annapurna; DEWAL, ML. An integrated method for hemorrhage segmentation from brain CT imaging. **Computers & Electrical Engineering**, Elsevier, v. 39, n. 5, p. 1527–1536, 2013.

BHADAURIA, N. S.; BIST, M. S.; PATEL, R. B.; BHADAURIA, H. S. Performance evaluation of segmentation methods for brain ct images based hemorrhage detection. In: Bharati Vidyapeeths Inst Comp Applicat & Management; IEEE Delhi Sect. **2015 2ND International Conference on Computing for Sustainable Global Development (INDIACOM)**. New Delhi, India, 2015. p. 1955–1959.

BISHOP, Christopher M. **Pattern Recognition and Machine Learning (Information Science and Statistics)**. Secaucus, NJ, USA: Springer-Verlag New York, Inc., 2006. ISBN 0387310738.

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

BUZUG, Thorsten M. **Computed tomography: from photon statistics to modern cone-beam CT**. Springer-Verlag Berlin Heidelberg: Springer Science & Business Media, 2008.

CANCELA, Diana Manuela Gomes. O acidente vascular cerebral - classificação, principais consequências e reabilitação. **Porto: ULP**, 2008.

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

CHARNOVSKI, Rafael. **Desenvolvimento de uma metodologia computacional para análise do fluxo cerebral utilizando tomografia computadorizada dinâmica**. Dissertação (Mestrado) — Universidade Federal de Santa Catarina, Programa de Pós-Graduação de Ciências da Computação, julho 2003. Dissertação de Mestrado.

CHAWLA, Mayank; SHARMA, Saurabh; SIVASWAMY, Jayanthi; KISHORE, L. T. A method for automatic detection and classification of stroke from brain CT images. In: IEEE Engn Med & Biol Soc. **2009 Annual International Conference of the IEEE Engineering in Medicine and Biology Society**. Minneapolis, Minnesota, 2009. p. 3581–3584. ISBN 978-1-4244-3295-0. ISSN 1557-170X.

CHEN, Gang; GU, Lixu; QIAN, Lijun; XU, Jianrong. An improved level set for liver segmentation and perfusion analysis in MRIs. **IEEE Transactions on Information Technology in Biomedicine**, v. 13, n. 1, p. 94–103, Jan 2009.

CHEN, Wei bin; ZHANG, Xin. A new watershed algorithm for cellular image segmentation based on mathematical morphology. In: **Machine Vision and Human-machine Interface (MVHI)**. Kaifeng, China: IEEE Computer Society, 2010. p. 653–656. ISBN 978-0-7695-4009-2.

CHIEN, Shao-Yi; HUANG, Yu-Wen; CHEN, Liang-Gee. Predictive watershed: a fast watershed algorithm for video segmentation. **IEEE Transactions on Circuits and Systems for Video Technology**, v. 13, n. 5, p. 453–461, May 2003. ISSN 1051-8215.

CHUANG, Keh-Shih; TZENG, Hong-Long; CHEN, Sharon; WU, Jay; CHEN, Tzong-Jer. Fuzzy c-means clustering with spatial information for image segmentation. **Computerized Medical Imaging and Graphics**, v. 30, n. 1, p. 9–15, 2006.

DAGHER, Issam; TOM, Kamal El. Waterballoons: A hybrid watershed balloon snake segmentation. **Image and Vision Computing**, v. 26, n. 7, p. 905–912, 2008.

DALCA, Adrian Vasile; SRIDHARAN, Ramesh; CLOONAN, Lisa; FITZPATRICK, Kaitlin M; KANAKIS, Allison; FURIE, Karen L; ROSAND, Jonathan; WU, Ona; SABUNCU, Mert; ROST, Natalia S *et al.* Segmentation of cerebrovascular pathologies in stroke patients with spatial and shape priors. In: **Medical Image Computing and Computer-Assisted Intervention (MICCAI 2014)**. Boston, MA, USA: Springer, 2014. p. 773–780.

DICE, L.R. Measures of the amount of ecologic association between species. **Journal of Ecology**, New York, v. 26, p. 297–302, 1945.

DIGABEL, H; LANTUÉJOUL, Christian. Iterative algorithms. In: STUTTGART, WEST GERMANY: RIEDERER VERLAG. **Proceedings of the 2nd European Symposium Quantitative Analysis of Microstructures in Material Science, Biology and Medicine**. [S.l.], 1978. v. 19, n. 7, p. 8.

FENG, Chaolu; LI, Chunming; ZHAO, Dazhe; DAVATZIKOS, Christos; LITT, Harold. Segmentation of the left ventricle using distance regularized two-layer level set approach. In: **Medical Image Computing and Computer-Assisted Intervention–MICCAI 2013**. Nagoya, Japan: Springer, 2013. p. 477–484.

FREITAS, Claudio Fróes de. **Imaginologia: Série Abeno: Odontologia Essencial-Parte Clínica**. São Paulo: Artes Medicas Editora, 2013. ISBN 9788536702124.

GARCIA, Vicente; DOMINGUEZ, Humberto de Jesus Ochoa; MEDEROS, Boris. Analysis of discrepancy metrics used in medical image segmentation. **IEEE Latin America Transactions**, IEEE, v. 13, n. 1, p. 235–240, 2015.

GARG, Setu; UROOJ, Shabana; VIJAY, Ritu. Detection of cervical cancer by using thresholding & watershed segmentation. In: Bharati Vidyapeeths Inst Comp Applicat & Management; IEEE Delhi Sect. **2nd International Conference on Computing for Sustainable Global Development (INDIACom), 2015**. New Delhi, India, 2015. p. 555–559. ISBN 978-9-3805-4416-8.

- GILLEBERT, Céline R; HUMPHREYS, Glyn W; MANTINI, Dante. Automated delineation of stroke lesions using brain CT images. **NeuroImage: Clinical**, Elsevier, v. 4, p. 540–548, 2014.
- GONZALEZ, Rafael C.; WOODS, Richard E. **Processamento Digital de Imagens**. 3. ed. São Paulo: São Paulo: Pearson Prentice Hall, 2010. ISBN 9788576054016.
- GONÇALVES, Andréa; SANNOMYIA, Eduardo Kazuo; LUGÃO, Carlos Eduardo B.; GONÇALVES, Marcelo. Identificação de pacientes com risco de acidente vascular cerebral pela radiografia panorâmica. **Jornal Brasileiro de Clínica Odontológica Integrada**, v. 8, n. 44, p. 162–164, 2004.
- GRAU, Vicente; MEWES, AUJ; ALCANIZ, M; KIKINIS, Ron; WARFIELD, Simon K. Improved watershed transform for medical image segmentation using prior information. **IEEE Transactions on Medical Imaging**, v. 23, n. 4, p. 447–458, APR 2004. ISSN 0278-0062.
- HAJIMANI, Elmira; RUANO, Carina A; RUANO, M Graca; RUANO, Antonio E. A software tool for intelligent CVA diagnosis by cerebral computerized tomography. In: **IEEE International Symposium on Intelligent Signal Processing (WISP)**. Funchal, Portugal: IEEE, 2013. p. 103–108.
- HOLMES, Erskine J; FORREST-HAY, Anna C; MISRA, Rakesh R. **Interpretation of emergency head CT: a practical handbook**. 1. ed. United Kingdom: Cambridge University Press, 2008. ISBN 1139471406, 9781139471404.
- HOUNSFIELD, Godfrey N. Computerized transverse axial scanning (tomography): Part 1. description of system. **The British journal of radiology**, The British Institute of Radiology, v. 46, n. 552, p. 1016–1022, 1973.
- HOUNSFIELD, Godfrey N. Computed medical imaging. **Journal of computer assisted tomography**, LWW, v. 4, n. 5, p. 665–674, 1980.
- HUANG, Juying; JIAN, Fengzeng; WU, Hao; LI, Haiyun. An improved level set method for vertebra CT image segmentation. **Biomedical Engineering Online**, BioMed Central Ltd, v. 12, n. 1, p. 48, 2013.
- JAARSMA, Caroline; LEINER, Tim; BEKKERS, Sebastiaan C.; CRIJNS, Harry J.; WILDBERGER, Joachim E.; NAGEL, Eike; NELEMANS, Patricia J.; SCHALLA, Simon. Diagnostic performance of noninvasive myocardial perfusion imaging using single-photon emission computed tomography, cardiac magnetic resonance, and positron emission tomography imaging for the detection of obstructive coronary artery diseasea meta-analysis. **Journal of the American College of Cardiology**, v. 59, n. 19, p. 1719–1728, 2012.
- KAVITHA, AR; CHELLAMUTHU, C. Detection of brain tumour from MRI image using modified region growing and neural network. **The Imaging Science Journal**, Taylor & Francis, v. 61, n. 7, p. 556–567, 2013.
- KIMIA, Benjamin B; TANNENBAUM, Allen R; ZUCKER, Steven W. Shapes, shocks, and deformations i: the components of two-dimensional shape and the reaction-diffusion space. **International Journal of Computer Vision**, Springer, v. 15, n. 3, p. 189–224, 1995.

KLEIN, Allan L.; ABBARA, Suhny; AGLER, Deborah A.; APPLETON, Christopher P.; ASHER, Craig R.; HOIT, Brian; HUNG, Judy; GARCIA, Mario J.; KRONZON, Itzhak; OH, Jae K.; RODRIGUEZ, E. Rene; SCHAFF, Hartzell V.; SCHOENHAGEN, Paul; TAN, Carmela D.; WHITE, Richard D. American society of echocardiography clinical recommendations for multimodality cardiovascular imaging of patients with pericardial disease: Endorsed by the society for cardiovascular magnetic resonance and society of cardiovascular computed tomography. **Journal of the American Society of Echocardiography**, v. 26, n. 9, p. 965 – 1012.e15, 2013. ISSN 0894-7317.

KUMMER, Rüdiger v; BOZZAO, Luigi; MANELFE, Claude. **Early CT diagnosis of hemispheric brain infarction**. 1. ed. Springer-Verlag Berlin Heidelberg: Springer Science & Business Media, 2012.

KUMMER, Rüdiger von. The impact of computed tomography on acute stroke treatment. In: **Thrombolytic Therapy for Acute Stroke**. USA: Springer, 2005. p. 249–278.

LEE, Jeongjin; KIM, Namkug; LEE, Ho; SEO, Joon Beom; WON, Hyung Jin; SHIN, Yong Moon; SHIN, Yeong Gil. An automatic method for fast and accurate liver segmentation in CT images using a shape detection level set method. In: INTERNATIONAL SOCIETY FOR OPTICS AND PHOTONICS. **Medical Imaging**. San Diego, CA, 2007. p. 65122V–65122V.

LEE, Yongbum; TAKAHASHI, Noriyuki; TSAI, Du-Yih; FUJITA, Hiroshi. Detectability improvement of early sign of acute stroke on brain ct images using an adaptive partial smoothing filter. In: INTERNATIONAL SOCIETY FOR OPTICS AND PHOTONICS. **Medical Imaging**. San Diego, California, 2006. p. 61446Q–61446Q.

LEOW, Alex; YU, CL; LEE, SJ; HUANG, SC; PROTAS, H; NICOLSON, R; HAYASHI, KM; TOGA, Arthur W; THOMPSON, Paul M. Brain structural mapping using a novel hybrid implicit/explicit framework based on the level-set method. **NeuroImage**, Elsevier, v. 24, n. 3, p. 910–927, 2005.

LI, Chunming; KAO, Chiu-Yen; GORE, John C; DING, Zhaohua. Minimization of region-scalable fitting energy for image segmentation. **IEEE transactions on image processing**, v. 17, n. 10, p. 1940–1949, 2008.

LI, Chunming; XU, Chenyang; GUI, Changfeng; FOX, Martin D. Level set evolution without re-initialization: a new variational formulation. In: IEEE Comp Soc. **IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR 2005)**. San Diego, CA, 2005. v. 1, p. 430–436.

LI, Ying; LI, ChuanLong; ZHANG, YuanZhi. Novel level set model for the image segmentation based on parzen-window. In: IEEE. **IEEE International Conference on Computer Science and Automation Engineering (CSAE), 2012**. Zhangjiajie, China, 2012. v. 3, p. 217–221.

LI, Zhijun; YANG, Kun; BOGDAN, Stjepan; XU, Bugong. On motion optimization of robotic manipulators with strong nonlinear dynamic coupling using support area level set algorithm. **International Journal of Control, Automation and Systems**, Springer, v. 11, n. 6, p. 1266–1275, 2013.

LOTUFO, Paulo Andrade. Stroke in brazil: a neglected disease. **São Paulo Medical Journal**, SciELO Brasil, v. 123, n. 1, p. 3–4, 2005.

LOW, Stephanie C; BAIN, Gregory I; FINDLAY, David M; ENG, Kevin; PERILLI, Egon. External and internal bone micro-architecture in normal and kienböck's lunates: A whole-bone micro-computed tomography study. **Journal of Orthopaedic Research**, Wiley Online Library, v. 32, n. 6, p. 826–833, 2014.

LOZANO, Rafael; NAGHAVI, Mohsen; FOREMAN, Kyle; LIM, Stephen; SHIBUYA, Kenji; ABOYANS, Victor; ABRAHAM, Jerry; ADAIR, Timothy; AGGARWAL, Rakesh; AHN, Stephanie Y *et al.* Global and regional mortality from 235 causes of death for 20 age groups in 1990 and 2010: a systematic analysis for the global burden of disease study 2010. **The Lancet**, Elsevier, v. 380, n. 9859, p. 2095–2128, 2013.

LUIZ, J. A. O.; MARQUES, M. A.; SOARES, R. T.; JR, G. Botura; LEMOS, M. A. de. Auxílio ao diagnóstico do glaucoma baseado em métodos de processamento digital de imagens. **XXIV Congresso Brasileiro de Engenharia Biomédica – CBEB**, 2014. UNESP - Sorocaba.

MAIER, Oskar; WILMS, Matthias; GABLENTZ, Janina von der; KRÄMER, Ulrike M; MÜNTE, Thomas F; HANDELS, Heinz. Extra tree forests for sub-acute ischemic stroke lesion segmentation in MR sequences. **Journal of Neuroscience Methods**, Elsevier, v. 240, p. 89–100, 2015.

MANZI, Flávio Ricardo; BóSCOLO, Frab Norberto; ALMEIDA, Solange Maria de; NETO, Francisco Haíter. Panoramic radiography as an auxiliary in detecting patients at risk for cerebrovascular accident (CVA): a case report. **Journal of Oral Science**, Nihon University School of Dentistry, v. 45, n. 3, p. 177–180, 2003.

MARQUES, Paulo M. de A. Diagnóstico auxiliado por computador na radiologia. **Radiologia Brasileira**, SciELO Brasil, v. 34, n. 5, p. 285–293, 2001.

MARQUES, Regis C. P. **Caracterização de Regiões em Imagens de Radar de Abertura Sintética com Aplicações de Segmentação por level set**. Tese (Doutorado) — Universidade Federal do Ceará, Fortaleza, 2011.

MARQUES, Regis C. Pinheiro; MEDEIROS, Fatima N.; NOBRE, Juvencio Santos. SAR Image Segmentation Based on Level Set Approach and G(A)(0) Model. **IEEE transactions on pattern analysis and machine intelligence**, v. 34, n. 10, p. 2046–2057, oct 2012. ISSN 0162-8828.

MASOUMI, Hassan; BEHRAD, Alireza; POURMINA, Mohammad Ali; ROOSTA, Alireza. Automatic liver segmentation in MRI images using an iterative watershed algorithm and artificial neural network. **Biomedical Signal Processing and Control**, Elsevier, v. 7, n. 5, p. 429–437, 2012.

MATESIN, M; LONCARIC, S; PETRAVIC, D. A rule-based approach to stroke lesion analysis from CT brain images. In: IEEE Reg 8; EURASIP. **ISPA 2001: Proceedings of the 2nd International Symposium on Image and Signal Processing and Analysis**. Pula, Croatia, 2001. p. 219–223. ISBN 953-96769-4-0.

MATESIN, M; LONCARIC, S; PETRAVIC, D. A rule-based approach to stroke lesion analysis from CT brain images. In: IEEE Reg 8; EURASIP. **ISPA 2001: Proceedings of the 2nd International Symposium on Image and Signal Processing and Analysis**. Pula, Croatia, 2001. p. 219–223. ISBN 953-96769-4-0.

MATTHEWS, Brian W. Comparison of the predicted and observed secondary structure of t4 phage lysozyme. **Biochimica et Biophysica Acta (BBA)-Protein Structure**, Elsevier, v. 405, n. 2, p. 442–451, 1975.

MENDIS, Shanthi; ARMSTRONG, T; BETTCHER, D; BRANCA, F; LAUER, J; MACE, C; POZNYAK, V; RILEY, L; SILVA, VDCE; STEVENS, G *et al.* Global status report on noncommunicable diseases 2014. **Switzerland: World Health Organization**, p. 14–15, 2014.

MENZE, B. H.; JAKAB, A.; BAUER, S.; KALPATHY-CRAMER, J.; FARAHANI, K.; KIRBY, J.; BURREN, Y.; PORZ, N.; SLOTBOOM, J.; WIEST, R.; LANCZI, L.; GERSTNER, E.; WEBER, M. A.; ARBEL, T.; AVANTS, B. B.; AYACHE, N.; BUENDIA, P.; COLLINS, D. L.; CORDIER, N.; CORSO, J. J.; CRIMINISI, A.; DAS, T.; DELINGETTE, H.; DEMIRALP, Ç; DURST, C. R.; DOJAT, M.; DOYLE, S.; FESTA, J.; FORBES, F.; GEREMIA, E.; GLOCKER, B.; GOLLAND, P.; GUO, X.; HAMAMCI, A.; IFTEKHARUDDIN, K. M.; JENA, R.; JOHN, N. M.; KONUKOGLU, E.; LASHKARI, D.; MARIZ, J. A.; MEIER, R.; PEREIRA, S.; PRECUP, D.; PRICE, S. J.; RAVIV, T. R.; REZA, S. M. S.; RYAN, M.; SARIKAYA, D.; SCHWARTZ, L.; SHIN, H. C.; SHOTTON, J.; SILVA, C. A.; SOUSA, N.; SUBBANNA, N. K.; SZEKELY, G.; TAYLOR, T. J.; THOMAS, O. M.; TUSTISON, N. J.; UNAL, G.; VASSEUR, F.; WINTERMARK, M.; YE, D. H.; ZHAO, L.; ZHAO, B.; ZIKIC, D.; PRASTAWA, M.; REYES, M.; LEEMPUT, K. Van. The Multimodal Brain Tumor Image Segmentation Benchmark (BRATS). **IEEE Transactions on Medical Imaging**, 34, n. 10, p. 1993–2024, Oct 2015. ISSN 0278-0062.

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

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

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

MOL, A; BALASUNDARAM, A. In vitro cone beam computed tomography imaging of periodontal bone. **Dentomaxillofacial Radiology**, v. 37, n. 6, p. 319–324, 2008.

MOREIRA, Francisco Diego Lima; KLEINBERG, Maurício Nunes; ARRUDA, Hemerson Furtado; FREITAS, Francisco Nélío Costa; PARENTE, Marcelo Monteiro Valente; ALBUQUERQUE, Victor Hugo Costa de; FILHO, Pedro Pedrosa Rebouças. A novel vickers hardness measurement technique based on adaptive balloon active contour method. **Expert Systems with Applications**, Elsevier, v. 45, p. 294–306, 2016.

MUSTAQEEM, Anam; JAVED, Ali; FATIMA, Tehseen. An efficient brain tumor detection algorithm using watershed & thresholding based segmentation. **International Journal of Image, Graphics and Signal Processing**, Modern Education and Computer Science Press, v. 4, n. 10, p. 34, 2012.

NAIDICH, Thomas P; CASTILLO, Mauricio; CHA, Soonmee; SMIRNIOTOPOULOS, James G. **Imaging of the Brain: Expert Radiology Series**. 1. ed. Philadelphia, PA: Elsevier Health Sciences, 2012. ISBN 9780323248044.

- NJEH, I.; AYED, I. Ben; HAMIDA, A. Ben. A distribution-matching approach to MRI brain tumor segmentation. In: IEEE; IEEE Engn Med & Biol Soc (EMBS); IEEE Signal Proc Soc. **9th IEEE International Symposium on Biomedical Imaging (ISBI)**. Barcelona, Spain, 2012. p. 1707–1710. ISBN 978-1-4577-1858-8. ISSN 1945-7928.
- NOBRE, Ricardo H.; RODRIGUES, Francisco A. A.; MARQUES, Regis C. P.; NOBRE, Juvencio S.; NETO, Jeova F. S. R.; MEDEIROS, Fatima N. S. SAR image segmentation with rnyis entropy. **IEEE Signal Processing Letters**, v. 23, n. 11, p. 1551–1555, Nov 2016. ISSN 1070-9908.
- OLIVEIRA, Paula Cristina; MOURA, João Paulo; FERNANDES, Luís Filipe; AMARAL, Elza Maria; OLIVEIRA, Ana Alexandra. A non-destructive method based on digital image processing for calculate the vigor and the vegetative expression of vines. **Computers and Electronics in Agriculture**, v. 124, p. 289 – 294, 2016. ISSN 0168-1699. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0168169916301454>>.
- PADMA, A.; SUKANESH, R. Segmentation and classification of brain CT images using combined wavelet statistical texture features. **Arabian Journal for Science and Engineering**, v. 39, n. 2, p. 767–776, 2014. ISSN 2191-4281. Disponível em: <<http://dx.doi.org/10.1007/s13369-013-0649-3>>.
- PARTY, Intercollegiate Stroke Working. **National clinical guideline for stroke**. UK: London: Royal College of Physicians, 2012.
- PENG, F.; YUAN, K.; FENG, S.; CHEN, W. Region feature extraction of brain ct image for classification. In: WUHAN UNIVERSITY. **2nd International Conference on Bioinformatics and Biomedical Engineering (ICBBE)**. Shanghai, 2008. p. 2495–2498.
- PHAM, Dzung L; XU, Chenyang; PRINCE, Jerry L. Current methods in medical image segmentation. **Annual review of biomedical engineering**, Annual Reviews 4139 El Camino Way, PO Box 10139, Palo Alto, CA 94303-0139, USA, v. 2, n. 1, p. 315–337, 2000.
- PONT-TUSET, Jordi; MARQUES, Ferran. Measures and meta-measures for the supervised evaluation of image segmentation. In: IEEE; IEEE Comp Soc. **2013 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)**. Portland, Oregon, 2013. p. 2131–2138. ISSN 1063-6919.
- PRZELASKOWSKI, Artur; SKLINDA, Katarzyna; BARGIEŁ, P; WALECKI, J; BIESIADKO-MATUSZEWSKA, M; KAZUBEK, M. Improved early stroke detection: wavelet-based perception enhancement of computerized tomography exams. **Computers in Biology and Medicine**, v. 37, n. 4, p. 524–533, 2007.
- QIAN, Xiaohua; WANG, Jiahui; GUO, Shuxu; LI, Qiang. An active contour model for medical image segmentation with application to brain ct image. **Medical Physics**, p. 179–187, 2013.
- RAJINI, N. Hema; BHAVANI, R. Computer aided detection of ischemic stroke using segmentation and texture features. **Measurement**, v. 46, n. 6, p. 1865 – 1874, 2013. ISSN 0263-2241.
- RAMALHO, G. L. B.; Rebouças Filho, P. P.; MEDEIROS, F. N. S. de; CORTEZ, P. C. Lung disease detection using feature extraction and extreme learning machine. **Revista Brasileira de Engenharia Biomédica**, v. 30, p. 207 – 214, 09 2014. ISSN 1517-3151.

Rebouças Filho, P. P.; CORTEZ, P. C.; FELIX, J. H. S.; CAVALCANTE, T. S.; HOLANDA, M. A. Adaptive 2D crisp active contour model applied to lung segmentation in CT images of the thorax of healthy volunteers and patients with pulmonary emphysema. **Brazilian Journal of Biomedical Engineering**, p. 363–376, 2013.

Rebouças Filho, P. P.; CORTEZ, P. C.; HOLANDA, M. A. Active contour modes crisp: new technique for segmentation the lungs in CT images. **Brazilian Journal of Biomedical Engineering**, v. 27, p. 259–272, 2011.

Rebouças Filho, P. P.; REBOUÇAS, E. de S.; MARINHO, L. B.; SARMENTO, R. M.; TAVARES, J. M. R. S.; ALBUQUERQUE, V. H. C. de. Analysis of human tissue densities: A new approach to extract features from medical images. **Pattern Recognition Letters**, 2017. ISSN 0167-8655. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0167865517300363>>.

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

RESTUM, Antonio Elias. **Ferramenta de Auxílio Diagnóstico para o Tratamento de Acidentes Vasculares Cerebrais**. Tese (Doutorado) — Universidade Federal do Rio de Janeiro - UFRJ, Coordenação dos Programa de Pós-Graduação de Engenharia, abril 2008. Tese de Doutorado.

RIBEIRO, Patricia B.; ROMERO, Roseli A.F.; OLIVEIRA, Patrícia R.; SCHIABEL, Homero; VERÇOSA, Luciana B. Automatic segmentation of breast masses using enhanced ICA mixture model. **Neurocomputing**, v. 120, n. 0, p. 61 – 71, 2013. ISSN 0925-2312. Image Feature Detection and Description.

ROTHWELL, PM. The high cost of not funding stroke research: a comparison with heart disease and cancer. **The Lancet**, Elsevier, v. 357, n. 9268, p. 1612–1616, 2001.

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

SAAD, Norhashimah Mohd; ABDULLAH, Abdul Rahim. Automated region growing for segmentation of brain lesion in diffusion-weighted MRI. In: INTERNATIONAL ASSOCIATION OF ENGINEERS. **International MultiConference of Engineers and Computer Scientists (IMECS)**. Hong Kong, 2012. p. 14–16.

SALMAN, Nassir H; GHAFOR, Bnar M; HADI, Gullanar M. Medical image segmentation based on edge detection techniques. **Advances in Image and Video Processing**, v. 3, n. 2, p. 1, 2015.

SANKARAN, Anush; JAIN, Aayush; VASHISTH, Tarun; VATSA, Mayank; SINGH, Richa. Adaptive latent fingerprint segmentation using feature selection and random decision forest classification. **Information Fusion**, Elsevier, v. 34, p. 1–15, 2017.

SARMENTO, Róger Moura; PEREIRA, Renato Francisco; COIMBRA, Pablo Picasso de Araújo; MACÊDO, Ana Carolina Nunes de; Rebouças Filho, Pedro P. Segmentação de acidente vascular cerebral em imagens de tomografia computadorizada: Um estudo comparativo. In: **VII Simpósio de Instrumentação e Imagens Médicas (SIIM)**. UNICAMP: SIIM, 2015.

SAYAH, Badredine; TIGHIOUART, Bornia. Brain tumour segmentation in MRI: knowledge-based system and region growing approach. **International Journal of Biomedical Engineering and Technology**, Inderscience Publishers Ltd, v. 14, n. 1, p. 71–89, 2014.

SERRA, J.; SOILLE, P. **Mathematical Morphology and Its Applications to Image Processing**. Uppsala, Sweden: Springer Netherlands, 2012. (Computational Imaging and Vision).

SETHIAN, J. A. **Level Set Methods and Fast Merging Methods: Evolving Interfaces in Computational Geometry, Fluid Mechanics, Comput. Vision and Materials Science**. 1. ed. Cambridge: Cambridge University Press, 1999.

SHARMA, Y.; MEGHRAJANI, Y. K. Brain tumor extraction from MRI image using mathematical morphological reconstruction. In: CURRAN ASSOCIATES, INC. **2nd International Conference on Emerging Technology Trends in Electronics, Communication and Networking (ET2ECN)**. Surat, India, 2014. p. 1–4.

SHOJAII, Rushin; ALIREZAIE, Javad; BABYN, Paul. Automatic lung segmentation in CT images using watershed transform. **IEEE International Conference on Image Processing-ICIP**, v. 2, p. 1270–1273, 2005.

SMEETS, Dirk; LOECKX, Dirk; STIJNEN, Bert; DOBBELAER, Bart De; VANDERMEULEN, Dirk; SUETENS, Paul. Semi-automatic level set segmentation of liver tumors combining a spiral-scanning technique with supervised fuzzy pixel classification. **Medical Image Analysis**, Elsevier, v. 14, n. 1, p. 13–20, 2010.

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

TANG, Fuk-hay; NG, Douglas KS; CHOW, Daniel HK. An image feature approach for computer-aided detection of ischemic stroke. **Computers in Biology and Medicine**, Elsevier, v. 41, n. 7, p. 529–536, 2011.

THAPALIYA, Kiran; PYUN, Jae-Young; PARK, Chun-Su; KWON, Goo-Rak. Level set method with automatic selective local statistics for brain tumor segmentation in MR images. **Computerized Medical Imaging and Graphics**, Elsevier, v. 37, n. 7, p. 522–537, 2013.

Chapter 2 - classifiers based on bayes decision theory. In: THEODORIDIS, Sergios; KOUTROUMBAS, Konstantinos (Ed.). **Pattern Recognition**. 4. ed. Boston: Academic Press, 2009. p. 13 – 89. ISBN 978-1-59749-272-0.

TIWARI, Kamlesh; GUPTA, Phalguni. An efficient technique for automatic segmentation of fingerprint ROI from digital slap image. **Neurocomputing**, v. 151, Part 3, p. 1163 – 1170, 2015. ISSN 0925-2312. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S092523121401354X>>.

WANG, Chunliang; FRIMMEL, Hans; SMEDBY, Örjan. Level-set based vessel segmentation accelerated with periodic monotonic speed function. In: INTERNATIONAL SOCIETY FOR OPTICS AND PHOTONICS. **SPIE Medical Imaging**. Lake Buena Vista, Florida, 2011. p. 79621M–79621M.

WANG, Chunliang; FRIMMEL, Hans; SMEDBY, Örjan. Fast level-set based image segmentation using coherent propagation. **Medical Physics**, American Association of Physicists in Medicine, v. 41, n. 7, p. 073501, 2014.

WANG, Li; SHI, Feng; LI, Gang; GAO, Yaozong; LIN, Weili; GILMORE, John H; SHEN, Dinggang. Segmentation of neonatal brain MR images using patch-driven level sets. **NeuroImage**, Elsevier, v. 84, p. 141–158, 2014.

WANG, Xiang-Yang; BU, Juan. A fast and robust image segmentation using fcm with spatial information. **Digital Signal Processing**, Elsevier, v. 20, n. 4, p. 1173–1182, 2010.

WEBB, W Richard; BRANT, William E; MAJOR, Nancy M. **Fundamentals of body CT**. 4. ed. UK: Elsevier Health Sciences, 2014. ISBN 9780323221467.

WORLD HEALTH ORGANIZATION. **Priority Medicines for Europe and the World**. WHO, 2004. Disponível em: <http://www.who.int/medicines/areas/priority_medicines/BP6_6Stroke.pdf?ua=1>. Acesso em: 28/01/2016.

WORLD HEALTH ORGANIZATION. **Cardiovascular diseases (CVDs)**. WHO, 2015. Disponível em: <<http://www.who.int/mediacentre/factsheets/fs317/en/>>. Acesso em: 28/01/2016.

YEUNG, DY; CHOW, C. Parzen-window network intrusion detectors. In: Int Assoc Pattern Recognit. **16th International Conference on Pattern Recognition**. Quebec City, Canada, 2002. p. 385–388. ISSN 1051-4651.

YOUSEM, David M; GROSSMAN, Robert I. **Neuroradiology: the requisites**. 3. ed. Philadelphia, PA: Elsevier Health Sciences, 2010. ISBN 9780323045216.

YUSHKEVICH, Paul A; PIVEN, Joseph; HAZLETT, Heather Cody; SMITH, Rachel Gimpel; HO, Sean; GEE, James C; GERIG, Guido. User-guided 3D active contour segmentation of anatomical structures: significantly improved efficiency and reliability. **Neuroimage**, Elsevier, v. 31, n. 3, p. 1116–1128, 2006.

ZUCKER, Steven W. Region growing: Childhood and adolescence. **Computer Graphics and Image Processing**, Elsevier, v. 5, n. 3, p. 382–399, 1976.