



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

Vítor Alencar de Mesquita

CONTORNOS ATIVOS GEOMÉTRICOS E PARAMÉTRICOS
APLICADOS À SEGMENTAÇÃO DO VENTRÍCULO
ESQUERDO EM IMAGENS DE ECOCARDIOGRAFIA

FORTALEZA - CEARÁ
DEZEMBRO - 2012

© Vítor Alencar de Mesquita, 2012

Vítor Alencar de Mesquita

CONTORNOS ATIVOS GEOMÉTRICOS E PARAMÉTRICOS
APLICADOS À SEGMENTAÇÃO DO VENTRÍCULO
ESQUERDO EM IMAGENS DE ECOCARDIOGRAFIA

DISSERTAÇÃO

Dissertação submetida ao corpo docente da Coordenação do Programa de Pós-Graduação em Engenharia de Teleinformática da **Universidade Federal do Ceará** como parte dos requisitos necessários para obtenção do grau de MESTRE EM ENGENHARIA DE TELEINFORMÁTICA.

Área de concentração: Sinais e Sistemas

Prof. Dr. Paulo César Cortez
(Orientador)

FORTALEZA - CEARÁ

2012

**Contornos Ativos Geométricos e Paramétricos Aplicados à
Segmentação do Ventrículo Esquerdo em Imagens de
Ecocardiografia**

Vítor Alencar de Mesquita

Dissertação de Mestrado aprovada em 17/12/2012.

Prof. Dr. Paulo César Cortez
(Orientador)

Prof. Dr. Wagner Coelho de Albuquerque Pereira

Prof. Dr. Auzuir Ripardo de Alexandria

Prof. Dr. Tarcísio Ferreira Maciel

A minha namorada, familiares e amigos...

Sumário

Lista de Figuras	vii
Lista de Tabelas	xi
Lista de Siglas	xii
Resumo	xiii
Abstract	xiv
Agradecimentos	xv
1 Introdução	1
1.1 Objetivos	6
1.2 Resumo das Contribuições	6
1.3 Organização do Trabalho	7
2 Fundamentação Teórica e Estado da Arte	8
2.1 Imagem Digital	10
2.2 Histograma	11
2.3 Limiarização	13
2.4 Gradiente	14
2.5 Aquisição de Imagens e Pré-processamento	16
2.6 Segmentação	17
2.7 Contornos Ativos	19
2.8 Frentes Propagantes	21
3 Método <i>Level-Set</i> Orientado por Gradiente	22
3.1 Aproximação Numérica	23
3.2 Ajuste de Parâmetros	27
3.3 Inicialização	27
3.4 Filtragem do Hamiltoniano	29
3.5 Função Sinal	29
4 Método <i>Level-Set</i> Orientado por Regiões	31
4.1 Fundamentação Teórica	32
4.2 Formulação <i>Level-Set</i>	33
4.3 Regularização e Tamanho do Contorno	35
4.4 Equação do Movimento	36

5	Método dos Contornos Ativos Algébricos	37
5.1	Formulação do Método dos Contornos Ativos Algébricos	37
5.1.1	Superposição de Gradientes	40
5.2	<i>PSnakes</i>	41
6	Resultados em Imagens Sintéticas	45
6.1	Metodologia dos Testes em Imagens Sintéticas	45
6.2	Resultados Para Objeto com Concavidade	47
6.3	Resultados Para Objeto com Borda Descontínua	48
6.4	Resultados Para Vários Objetos	48
6.5	Resultados Para Regiões Não-Homogêneas	48
6.6	Resultados em Imagens Ruidosas	49
6.7	Conclusão do Capítulo	50
7	Resultados em Imagens de Ecocardiografia	63
7.1	Metodologia dos Testes em Imagens de Ecocardiografia	63
7.2	Resultados com Inicialização Próxima ao Ventrículo Esquerdo	64
7.3	Resultados com Inicialização Próxima aos Pontos Extremos da Imagem	65
7.4	Resultados de Segmentação na Sístole e na Diástole	65
7.5	Comparação dos Resultados com o Padrão-Ouro	65
7.6	Conclusão do Capítulo	68
8	Conclusão e Trabalhos Futuros	85
	Referências Bibliográficas	89

Lista de Figuras

2.1	exemplo de histograma de uma imagem; (a) imagem de ecocardiograma típica e (b) histograma de uma imagem de ecocardiograma típica.	12
2.2	(a) imagem de raios-X original. (b) imagem de raios-X binarizada com limiar igual a 17 e (c) limiar igual a 27.	13
2.3	histograma da imagem 2.2 (a).	14
3.1	curva de contorno (em vermelho) da superfície no nível 0.	23
3.2	distorções causadas pela propagação do erro (frente inicial em azul).	24
3.3	influência da curvatura do contorno sobre a velocidade (contorno inicial azul e no interior); (a) $\epsilon = 0$ e (b) $\epsilon = 0,25$	28
3.4	inicialização do método <i>level-set</i> orientado por gradiente.	28
4.1	efeitos no contorno da variação das integrais presentes no funcional de energia (equação 4.1).	33
5.1	janela de busca pelo <i>pixel</i> de menor energia (em vermelho) no método dos contornos ativos tradicionais.	38
5.2	cálculo do termo de curvatura com 5 pontos.	39
5.3	sistema de coordenadas e parametrização do contorno no método <i>PSnakes</i> (ALEXANDRIA, 2011).	42
6.1	resultados obtidos pelo método <i>level-set</i> orientado por gradiente em imagem com concavidades (a) com inicialização próxima aos pontos extremos da imagem, (b) 14 iterações e (c) 30 iterações; (d) com inicialização dentro do objeto, (e) 42 iterações e (f) 60 iterações.	52
6.2	contorno obtido pelo método <i>level-set</i> orientado por regiões em imagem com concavidades (a) com inicialização próxima aos pontos extremos da imagem e (b) após 50 iterações; (c) com inicialização dentro do objeto e (d) após 50 iterações.	53

6.3	resultados obtidos pelo MCA algébrico em imagem com concavidades (a) com inicialização ao redor do objeto e (b) após 25 iterações; (c) com inicialização dentro do objeto e (d) após 60 iterações	54
6.4	resultado obtido pelo método <i>level-set</i> orientado por gradiente em imagem com bordas descontínuas (a) após inicialização dentro do objeto, (b) 32 iterações, (c) 50 iterações e (d) 75 iterações.	55
6.5	resultado obtido pelo MCA algébrico em imagem com bordas descontínuas (a) após inicialização dentro do objeto com bordas descontínuas e (b) após 60 iterações.	55
6.6	resultado obtido pelo método <i>level-set</i> orientado por gradiente para vários objetos (a) após inicialização próxima aos pontos extremos da imagem, (b) 24 iterações e (c) 30 iterações.	56
6.7	resultado obtido pelo MCA algébrico para vários objetos (a) após inicialização fora da região de interesse e (b) após 30 iterações.	57
6.8	(a) exemplo de imagem não-homogênea binarizada por limiar; resultado obtido pelo método <i>level-set</i> orientado por gradiente para regiões não-homogêneas (b) após inicialização próxima aos pontos extremos da imagem, (c) 25 iterações e (d) 40 iterações.	58
6.9	resultado obtido pelo método <i>level-set</i> orientado por regiões para regiões não-homogêneas (a) após inicialização próxima aos pontos extremos da imagem, (b) 15 iterações e (c) 50 iterações.	59
6.10	resultado obtido pelo MCA algébrico para regiões não-homogêneas (a) após inicialização próxima aos pontos extremos da imagem, (b) 15 iterações e (c) 30 iterações.	60
6.11	resultados obtidos pelo método <i>level-set</i> orientado por gradiente aplicado a imagem com SNR de (a) 39,52 dB, (b) 32,54 dB e (c) 31,07 dB.	61
6.12	resultados obtidos pelo método <i>level-set</i> orientado por regiões aplicado a imagem com SNR de (a) 39,52 dB, (b) 32,54 dB, (c) 31,07 dB e (d) 22,55 dB.	62
6.13	resultados obtidos pelo MCA algébrico aplicado a imagem com SNR de (a) 39,52 dB e (b) 32,54 dB.	62
7.1	medida de distância d_i entre o contorno de referência C_r e o contorno resultante da segmentação C_s	67
7.2	resultado obtido pelo método <i>level-set</i> orientado por gradiente após (a) inicialização nas bordas do feixe de ultrassom (b) 7 iterações e (c) 15 iterações.	70

7.3	resultado obtido pelo método <i>level-set</i> orientado por regiões após (a) inicialização nas bordas do feixe de ultrassom (b) uma iteração e (c) 3 iterações.	71
7.4	resultado obtido pelo MCA algébrico após (a) inicialização dentro da cavidade do ventrículo esquerdo, (b) 25 iterações e (c) 100 iterações.	72
7.5	resultado obtido pelo método <i>level-set</i> orientado por gradiente após (a) inicialização nos pontos extremos da imagem, (b) 7 iterações e (c) 20 iterações.	73
7.6	resultado obtido pelo método <i>level-set</i> orientado por regiões após (a) inicialização nos pontos extremos da imagem, (b) 4 iterações e (c) 20 iterações.	74
7.7	resultado obtido pelo MCA algébrico após (a) inicialização nos pontos extremos da imagem, (b) 5 iterações e (c) 25 iterações.	75
7.8	resultado obtido pelo método <i>level-set</i> orientado por gradiente aplicado a imagem da sístole do ventrículo esquerdo após 50 iterações.	76
7.9	resultado obtido pelo método <i>level-set</i> orientado por gradiente aplicado a imagem da diástole do ventrículo esquerdo após 50 iterações.	76
7.10	método <i>level-set</i> orientado por regiões aplicado a imagem da sístole do ventrículo esquerdo após 3 iterações.	77
7.11	resultado obtido pelo método <i>level-set</i> orientado por regiões aplicado a imagem da diástole do ventrículo esquerdo após 3 iterações.	77
7.12	resultado obtido pelo MCA algébrico aplicado a imagem da sístole do ventrículo esquerdo após 25 iterações.	78
7.13	resultado obtido pelo MCA algébrico aplicado a imagem da diástole do ventrículo esquerdo após 25 iterações.	78
7.14	Comparação do resultado obtido pelo MCA algébrico (em vermelho) com o padrão-ouro fornecido por especialista (em verde) em uma (a) sístole e em uma (b) diástole.	79
7.15	Comparação do resultado obtido pelo MCA algébrico (em vermelho) com o padrão-ouro fornecido por especialista (em verde) em uma (a) sístole e em uma (b) diástole.	80
7.16	Comparação do resultado obtido pelo MCA algébrico (em vermelho) com o padrão-ouro fornecido por especialista (em verde) em uma (a) sístole e em uma (b) diástole.	81
7.17	Comparação do resultado obtido pelo MCA algébrico (em vermelho) com o padrão-ouro fornecido por especialista (em verde) em uma (a) sístole e em uma (b) diástole.	82

7.18	(a) exemplo de imagem de ecocardiograma na sístole; (b) padrão-ouro (em verde) apontado por médico especialista.	83
7.19	(a) exemplo de imagem de ecocardiograma na diástole; (b) padrão-ouro (em verde) apontado por médico especialista.	84
8.1	segmentação do disco óptico resultante da aplicação do MCA algébrico (contorno em azul) em imagem do globo ocular.	86
8.2	(a) imagem original de uma tomografia computadorizada do tórax (b) resultado da segmentação do pulmão e tórax utilizando o método <i>level-set</i> orientado por gradiente.	88

Lista de Tabelas

6.1	Parâmetros do método <i>level-set</i> orientado por gradiente aplicado à imagens sintéticas	45
6.2	Parâmetros do método <i>level-set</i> orientado por regiões aplicado a imagens sintéticas	46
6.3	Parâmetros do método dos contornos ativos algébricos aplicado a imagens sintéticas	46
7.1	Parâmetros utilizados para imagens de ecocardiografia	63
7.2	Erro Médio Quadrático da Área	66
7.3	Erro Médio Quadrático da Distância	67

Lista de Siglas

AWGN	<i>Additive White Gaussian Noise</i>
CCD	<i>Charge Coupled Device</i>
EMQ	Erro Médio Quadrático
MCA	Método dos Contornos Ativos
PDI	Processamento Digital de Imagens
SNR	<i>Signal-to-Noise Ratio</i>
VE	Ventrículo Esquerdo

Resumo

A identificação correta do ventrículo esquerdo em imagens de ecocardiograma constitui uma importante ferramenta no auxílio ao diagnóstico precoce de doenças cardiovasculares. No entanto, limitações inerentes ao processo de aquisição das imagens, como baixa relação sinal-ruído e presença de sombras acústicas, tornam essa identificação uma tarefa complexa. Neste trabalho, com o objetivo de segmentar o ventrículo esquerdo, contornos ativos geométricos e paramétricos são aplicados sobre imagens de ecocardiografia. Uma nova variação dos contornos ativos paramétricos, o método dos contornos ativos algébricos, e duas modalidades de método *level-set*, uma baseada no gradiente e outra baseada em regiões, são testadas e comparadas. São propostas, neste trabalho, quatro contribuições à literatura. Uma é a filtragem do Hamiltoniano por uma janela gaussiana a fim de acelerar o movimento do contorno. Outra é uma função sinal, que permite que o contorno mude sua direção radial automaticamente. Além disso, a própria concepção do método dos contornos ativos algébricos é uma das contribuições. Finalmente, a última é a superposição de mapas de contorno, que aumenta a área de influência do contorno ativo sem perda de precisão. Conclui-se que, apesar da capacidade dos contornos ativos geométricos de dividirem-se e unificarem-se independentemente de novas parametrizações, o método dos contornos ativos algébricos é, dentre os avaliados, o único capaz de realizar a segmentação do ventrículo esquerdo nas imagens de ecocardiografia conforme o padrão-ouro fornecido pelos especialistas.

Palavras-chave: Contornos Ativos, Ecocardiografia, Processamento Digital de Imagens, *Level-set*.

Abstract

The correct left ventricle identification in echocardiography images constitutes an important tool to early diagnosis of heart diseases. However, limitations inherent to the image acquisition process, as low signal-to-noise ratio and presence acoustic shadows, make this identification a complex task. In this work, purposing to segment the left ventricle, geometric and parametric active contours are applied over echocardiography images. A new parametric active contours variation, the algebraic active contours method, and two kinds of level-set methods, one based on gradient and another based on regions, are tested and compared. In this work, four contributions to literature are proposed. One is the Hamiltonian filtering by a gaussian window in order to accelerate the contour movement. Another one is a signal function, that allows the contour to change automatically its radial direction. Moreover, the algebraic active contours method conception itself is one of the contributions. Finally, the last one is the contours map superposition, that increases active contour's influence area without accuracy loss. It is concluded that, although the geometric active contours capacity of splitting and merging itself independently of new parametrizations, the algebraic active contours method is, among the evaluated methods, the only one able to segment the left ventricle in echocardiography images conform to the gold-standard provided by the specialists.

Keywords: Active Contours, Echocardiography, *Level-set*, Digital Image Processing.

Agradecimentos

Dedico meus sinceros agradecimentos a:

- Deus, pela vida;
- meu orientador Paulo César Cortez, pela atenção e disponibilidade;
- meus pais Jarbas e Ofélia, por seu amor e seu grande apoio;
- minha namorada Manuela, pelo carinho e pela confiança;
- minhas irmãs Marta e Ana Luísa, pela compreensão e paciência;
- todos os meus verdadeiros amigos, inclusive a Diego Maia e a meus companheiros de laboratório Tarique, Thomáz, Alyson e Auzuir, pela ajuda e companheirismo;
- Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio financeiro;
- Hospital Universitário Walter Cantídio, Prontocárdio e Dr. Abreu pela cessão das imagens;

Capítulo 1

Introdução

Doenças cardiovasculares são as que mais causam mortes de seres humanos no mundo, superando males como anomalias cerebrovasculares, mal de Alzheimer, diabetes *mellitus* e cânceres de pulmão, mama, cólon e reto. A taxa de mortalidade apenas devido a cardiopatias chega, em média, a 16% em países considerados desenvolvidos e 12% em países considerados sub-desenvolvidos ou em desenvolvimento (OMS, 2008).

Segundo dados do Ministério da Saúde, a cada 100 mil brasileiros, 96 vão a óbito por ano devido a doenças isquêmicas no coração. Este número tem aumentado nas últimas duas décadas e está possivelmente relacionado ao crescimento dos principais indicadores de fatores de risco como consumo abusivo de bebidas alcoólicas e hipertensão arterial.

Todavia, para que se possa alcançar uma diminuição dessas taxas de mortalidade, são necessários, além do controle dos fatores de risco, mecanismos que venham a fornecer diagnósticos acurados, em tempo hábil, para a realização de um possível tratamento. O diagnóstico precoce de doenças coronárias previne infartos e, além de reduzir a mortalidade, diminui seus custos sociais (BOUHOURS, 2006).

Dentre os exames disponíveis para o auxílio ao diagnóstico de doenças cardíacas há dois que se destacam (JÚNIOR, 2010). O primeiro deles é o eletrocardiograma, que registra mudanças de potencial elétrico devido às atividades eletroquímicas envolvidas na formação e propagação espacial das excitações elétricas nas células do coração (HAYKIN; VEEM, 2001). O segundo exame é o ecocardiograma, que consiste na obtenção de imagens das estruturas cardíacas através da reflexão e espalhamento de ondas de ultrassom emitidas e posteriormente captadas por dispositivos específicos (OTTO, 2004).

A ecocardiografia é uma técnica que investiga o estado das estruturas internas do coração utilizando ultrassonografia. Trata-se de uma ferramenta de auxílio ao diagnóstico de doenças cardíacas destinada a detectar anomalias na morfologia ou no funcionamento

das câmaras do coração (átrios e ventrículos), de suas válvulas (aórtica, mitral, tricúspide e pulmonar) e de seus principais vasos (veias pulmonares, artérias pulmonares, veias cavas e aorta).

O ecocardiógrafo, equipamento utilizado para proceder ao exame de ecocardiografia, tem como princípio de funcionamento a reflexão e o retroespalhamento das ondas mecânicas que chegam ao coração. Um transdutor é usado para produzir ondas acústicas tipicamente na faixa de 3 a 15 MHz, bem como para detectar o sinal que retorna para produzir as imagens (ALEXANDRIA, 2011).

Em um sentido estrito, transdutor é um dispositivo que converte uma forma de energia em outra através de um elemento sensor. Um transdutor de ultrassom é um cristal piezoelétrico (quartzo, por exemplo) sobre o qual a aplicação de um campo elétrico resulta no alinhamento de suas partículas polarizadas na direção perpendicular à sua face, e, conseqüentemente, em sua expansão. Quando uma sequência de pulsos elétricos é aplicada sobre o cristal, este se expande e se comprime, gerando uma onda de ultrassom. Este transdutor funciona tanto como transmissor quanto como receptor, convertendo energia elétrica em mecânica e vice-versa (OTTO, 2004).

As interfaces de tecidos suaves cuja dimensão lateral seja maior que o comprimento de onda do ultrassom tendem a irradiar os feixes uniformemente em determinada direção, a depender do ângulo de incidência, agindo como refletores especulares. Conforme se propagam através dos tecidos, as ondas de ultrassom perdem energia pela conversão em calor e pelo espalhamento causado por estruturas geralmente menores que um comprimento de onda (OTTO, 2004). Esta perda é conhecida por atenuação e possui dependência direta com o comprimento de onda, de modo que quanto menor o comprimento de onda, maior a atenuação e menor a penetração das ondas de ultrassom no corpo. Assim, evidencia-se um compromisso entre o alcance da imagem sobre os tecidos (penetração) e sua resolução (comprimento de onda).

Propriedades do tecido, tais como densidade, rugosidade e velocidade do fluxo sanguíneo modificam o padrão das ondas ecoadas para o equipamento de ultrassom (OTTO, 2004). Os ecos são detectados pelo transdutor, convertendo as ondas acústicas em sinais elétricos (ALEXANDRIA, 2011). As modificações nos padrões das ondas refletidas são processadas e representadas graficamente como uma imagem bidimensional. São considerados, entre outros fatores, o atraso entre a transmissão e o retorno do sinal refletido, sobre o qual processamentos são realizados até que se resulte em uma imagem inteligível. É a partir dessa imagem que o médico especialista se baseia para emitir seu laudo (JÚNIOR, 2010).

A partir da análise do ecocardiograma são obtidas informações a respeito do estado

dos ventrículos, como tamanho de suas câmaras, espessura de suas paredes, e débito cardíaco, ou seja, volume de sangue que passa por cada um dos ventrículos por minuto. Além disso, é possível detectar se há estenose ou incompetência valvular e quantificar o refluxo de sangue no caso desta última. Outros diagnósticos como aneurismas, anomalias no pericárdio, malformações nos vasos e cardiopatias congênicas podem ser inferidos com auxílio do referido exame.

Contudo, algumas alterações no músculo cardíaco ocasionalmente não podem ser detectadas em indivíduos em repouso, sendo necessário que haja uma isquemia em progresso para evidenciá-las. Por exemplo, na formação de um trombo bloqueador da circulação dentro da coronária, os vasos estreitados podem limitar a quantidade de sangue requerida quando submetidos a esforço, tornando evidente a isquemia (BOUHOURS, 2006).

Devido a essa dificuldade, é demandada a utilização do ecocardiograma de esforço (ECE). Este procedimento exige que o paciente seja submetido a esforço aeróbico em esteiras ou bicicletas ergométricas para a realização do exame. Todavia, sua execução nem sempre é factível, haja vista a idade do paciente, seu estado de saúde ou motivo diverso que o impossibilite ser submetido a esforço.

Nesses casos, deve-se fazer a aplicação intravenosa de dobutamina, substância que causa no coração efeito similar ao de um esforço aeróbico. Este tipo de ecocardiograma é chamado de ecocardiograma por estresse com dobutamina, EED na linguagem médica (MARKMAN, 1997). A utilização do EDD deve ter caráter suplementar, só devendo substituir o ECE quando necessário, pois, além de ser uma técnica invasiva, o EED não provoca nos tecidos a demanda por sangue que um esforço real provocaria, não produzindo, portanto, a pressão correspondente a tal demanda no coração.

Por ser uma técnica não-invasiva e de custo relativamente baixo, a ecocardiografia tradicional é comumente utilizada para visualizar o ventrículo esquerdo durante vários ciclos inteiros de funcionamento do coração (LEUNG et al., 2006). Comparado, por exemplo, à angioressonância cardíaca, ou angiografia por ressonância magnética cardíaca, exame de imagem que permite a visualização detalhada dos vasos cardíacos, o ecocardiograma possui o custo de 5 a 10 vezes menor. Além disso, por se tratar de um exame de imagens de ultrassom, o ecocardiograma pode evidenciar detalhes não revelados apenas pela análise do eletrocardiograma, como insuficiência ou estenose mitral.

Com base no exposto, o acompanhamento visual do ventrículo esquerdo é de fundamental importância para a análise do funcionamento do sistema cardiovascular, pois esta é a maior e mais potente câmara do coração, bombeando, através da aorta, o sangue arterial advindo do átrio esquerdo pela válvula mitral, e oxigenando todos os tecidos do

corpo. É através da análise do seu comportamento que várias doenças cardíacas podem ser diagnosticadas, sendo, no entanto, necessária sua clara identificação para que se percebam algumas das possíveis modificações no ventrículo examinado em relação a um saudável (OTTO, 2002).

O volume do ventrículo esquerdo e a fração de ejeção, ou seja, a porcentagem do volume de sangue recebido durante a diástole que é ejetada durante a sístole deste ventrículo são importantes medidas clínicas no auxílio ao diagnóstico e ao prognóstico de pacientes com doenças cardíacas (HANSEGARD J.; URHEIM S.; LUNDE, 2007). Além disso, capacidade de deformação dessa câmara é, também, uma informação relevante para a detecção de isquemia cardíaca, bem como para o planejamento cirúrgico (ALEXANDRIA et al., 2011). É possível estimar tais medidas através da identificação das bordas do ventrículo esquerdo em imagens do final de sua sístole e do final de sua diástole (CHALANA et al., 1996; FENG et al., 2009). Todavia, traçar manualmente essas bordas é uma tarefa laboriosa cujo resultado varia entre diferentes observadores, produzindo-se algum grau de subjetividade. No sentido de diminuir esse grau de subjetividade, são utilizadas técnicas de Processamento Digital de Imagens em exames de ecocardiografia.

A representação digital de imagens é utilizada em diversas áreas da Medicina, como pneumologia, cardiologia, traumatologia e neurologia. Estas imagens são obtidas, por exemplo, por equipamentos de Doppler colorido, tomografia computadorizada, ressonância magnética, ultrassonografia e medicina nuclear (FÉLIX, 2007). Informações relevantes presentes em tais imagens podem ser extraídas por meio de sistemas de visão computacional, o que contribui com o aumento da utilização destes sistemas em aplicações como: detecção, reconhecimento e classificação de objetos, estimativa de parâmetros, análise de formas e descrição de cenas (CAVALCANTE, 2010).

O desenvolvimento de sistemas computacionais aliado ao conhecimento médico possibilita a construção de equipamentos que têm se mostrado importantes quanto a identificação de doenças e seus tratamentos (ALEXANDRIA, 2011). Dentre os equipamentos desenvolvidos para o auxílio aos especialistas quanto ao diagnóstico, encontram-se: eletroencefalógrafo, eletrocardiógrafo, ecocardiógrafo, entre outros.

Apesar de aplicados a diversas áreas da Medicina, tais equipamentos têm em comum a utilização de imagens ou gráficos como representação do estado do objeto de análise (ALEXANDRIA, 2011). Sua utilização proporciona agilidade nos diagnósticos, visualização de detalhes imperceptíveis pela visão humana (ALEXANDRIA et al., 2011), e, conseqüentemente, mais confiabilidade nas análises realizadas e capacidade de proporcionar aos médicos em geral segurança adicional quanto aos procedimentos (FILHO et al.,

2006).

Dentre os equipamentos citados, o ecocardiógrafo é utilizado, conforme exposto, para a obtenção de imagens que mostram a dinâmica do coração, já tendo seu uso disseminado em Medicina e Telemedicina (JÚNIOR, 2010). Nos exames de ecocardiografia realizados rotineiramente com o amparo deste aparelho, as imagens normalmente não possuem o contraste adequado, e a identificação do ventrículo esquerdo é realizada pelo próprio médico, constituindo um julgamento subjetivo e sujeito a erro humano.

Nesse sentido, o conhecimento das limitações da técnica de ecocardiografia é um fator crítico para o fornecimento de um diagnóstico clínico correto e para a escolha de um tratamento adequado para o paciente. Por um lado, para vários cenários clínicos, a ecocardiografia pode auxiliar especialistas a tomar de decisões com alto grau de precisão. Por outro lado, se estruturas que aparecem no exame de ecocardiografia são confundidas com anomalias anatômicas, o paciente pode ser submetido a testes diagnósticos e intervenções terapêuticas desnecessárias, custosas e potencialmente arriscadas. Algumas das limitações inerentes à técnica de ecocardiografia são (OTTO, 2004):

- qualidade sub-ótima das imagens, devido à baixa relação sinal-ruído causada pela atenuação das ondas de ultrassom através dos tecidos;
- sombras acústicas, causadas por estruturas de acentuada impedância acústica através das quais a transmissão das ondas de ultrassom é atenuada;
- imagens duplas causadas pela reverberação e
- e limitações de processamento eletrônico, dependendo do tipo de equipamento.

Tendo em vista tais limitações, a aplicação em exames médicos de técnicas de Processamento Digital de Imagens (PDI) capazes de adquirir, processar e interpretar imagens pode auxiliar a resolução de problemas altamente complexos, por exemplo, definir com acurácia as estruturas importantes que não são facilmente visíveis nos exames de ecocardiograma (PREDINI H.; SCWART, 2007). Um dos fatos que sustenta a validade desse argumento é o de que o sistema de visão humano consegue distinguir simultaneamente apenas 32 níveis de tom de cinza, enquanto um sistema com imagens digitalizadas consegue distinguir 256 destes, utilizando apenas 8 *bits* (BOUHOURS, 2006).

A identificação automática do ventrículo esquerdo em imagens de ecocardiografia é uma tarefa desafiadora por várias razões. Em primeiro lugar, a qualidade da imagem de ultrassom é corrompida pelo ruído do tipo *speckle*, por sombras dos pulmões e das

costelas e pela absorção de energia pela gordura subcutânea. Somando-se a esses fatos, os músculos papilares são estruturas distintas dentro da cavidade que o ecocardiógrafo tende a não suprimir, e a válvula mitral, em sua abertura durante a diástole, pode ser interpretada erroneamente como parte da parede do ventrículo por uma delimitação viciosa deste (HANSEGARD J.; URHEIM S.; LUNDE, 2007).

Assim, as técnicas de segmentação utilizadas para identificar o ventrículo esquerdo em imagens extraídas de exames de ecocardiografia são importantes para um diagnóstico preciso e rápido, constituindo objetos de estudo deste trabalho.

1.1 Objetivos

O presente trabalho tem por objetivo geral a realização de uma análise comparativa entre técnicas de contornos ativos para segmentação de propósito geral e do ventrículo esquerdo em imagens de ecocardiografia. Para a consecução deste intento, busca-se a realização dos seguintes objetivos específicos:

- conceber uma nova variação de contornos ativos tradicionais ou paramétricos, chamada de método dos contornos ativos algébricos;
- implementar, testar e avaliar em imagens sintéticas o método dos contornos ativos algébricos e dois métodos *level-set*, um orientado por gradiente e outro por regiões, para segmentação de propósito geral;
- implementar, testar e avaliar o método dos contornos ativos algébricos e dois métodos *level-set*, um orientado por gradiente e outro por regiões, para segmentação do ventrículo esquerdo em imagens de ecocardiografia.

1.2 Resumo das Contribuições

Neste trabalho são propostas as seguintes contribuições à literatura:

- filtragem do fluxo Hamiltoniano por uma janela gaussiana no método *level-set* orientado por gradiente;
- incorporação de uma função sinal ao método *level-set* orientado por gradiente;
- concepção de um método de contornos ativos algébricos; e

- superposição de mapas de contorno para contornos ativos paramétricos.

A concepção do método dos contornos ativos algébricos é exposta no artigo completo de autoria de Vítor Alencar de Mesquita e Paulo César Cortez intitulado "Avaliação e Comparação de Métodos *Level-Set* e Contornos Ativos Paramétricos em Imagem Sintética e Imagens Retiradas de Exames de Ecocardiografia", publicado nas páginas 2458 a 2462 dos anais do XXIII CBEB (XXIII Congresso Brasileiro de Engenharia Biomédica), realizado de 1 a 5 de outubro do corrente ano em Porto de Galinhas, Pernambuco.

1.3 Organização do Trabalho

Expostos a motivação e os objetivos do trabalho, explana-se, a seguir, sobre a maneira como o restante está organizado. No Capítulo 2 são introduzidos conceitos importantes na área de Processamento Digital de Imagens que fundamentam o entendimento dos métodos apresentados.

No Capítulo 3 é apresentado o método *level-set* orientado por gradiente, bem como contribuições propostas para sua melhoria, sendo o método *level-set* orientado por regiões contemplado no Capítulo 4.

A concepção do método dos contornos ativos algébricos, bem como a utilização de mapas de contornos superpostos estão descritas no Capítulo 5. No mesmo Capítulo, o método *PSnakes* é brevemente abordado com o objetivo de fornecer um parâmetro de comparação quantitativa para o MCA algébrico.

Os métodos apresentados são testados em imagens sintéticas a fim de analisar seu comportamento diante de vários tipos de imagem e verificar sua capacidade de segmentação para propósito geral no Capítulo 6.

Em seguida, no Capítulo 7, os mesmos métodos são aplicados sobre imagens de ecocardiografia com o objetivo de segmentar o VE e avaliar sua utilidade para fins médicos.

Por fim, as conclusões, contribuições e trabalhos futuros são apresentados no Capítulo 8.

Capítulo 2

Fundamentação Teórica e Estado da Arte

O homem possui um sofisticado e complexo sistema de visão, ainda não totalmente compreendido, que utiliza a luz visível como fonte. Seu cérebro é capaz de reconhecer objetos e imagens em um tempo de aproximadamente 100 a 200 ms, ao passo que tarefas com menor grau de complexidade podem levar dias para serem executadas por computadores (HAYKIN, 1994; ALBUQUERQUE, 2007).

O cérebro humano é dotado de características úteis para uso em qualquer sistema de inteligência Computacional, como por exemplo: robustez e tolerância a falhas; flexibilidade, adaptabilidade e capacidade de aprendizado; capacidade de processar informação nebulosa, probabilística, ruidosa ou inconsistente; processamento paralelo; tamanho reduzido, grande capacidade de processamento e baixo consumo de energia (BARRETO, 1998).

Essas características conferem ao cérebro maior agilidade em relação ao computador de von Neumann para realizar tarefas como classificação de padrões, que consiste em atribuir a uma entrada o rótulo de uma classe pré-especificada, e clusterização, que procura similaridade entre os padrões de entrada sem que, todavia, haja dados de treinamento, ou seja, classes pré-estabelecidas (JAIN A.K.; MOHIUDDIN, 1996).

A frequência de *clock* de computadores atuais já chega à ordem de GHz, ao passo que a frequência de disparo de um neurônio é da ordem de kHz. Esta enorme discrepância provoca um questionamento natural sobre o motivo pelo qual algumas tarefas, como reconhecer um rosto em uma multidão, ou os caracteres em uma frase escrita a lápis, são realizadas com maior rapidez pelo cérebro humano que pelos computadores.

Apesar de possuir unidades de processamento mais lentas e simples, o cérebro humano

é composto por aproximadamente 10^{11} a 10^{12} dessas unidades: células nervosas chamadas neurônios. Os neurônios se interconectam através de caminhos de transmissão, formando uma complexa rede com cerca de 10^{15} interconexões (BARRETO, 1998). Esta rede processa os dados de entrada de forma distribuída e paralela, ao contrário de como ocorre na arquitetura de von Neumann, em que instruções armazenadas na memória são executadas sequencialmente por uma ou algumas poucas unidades de processamento.

Neste sentido, um dos maiores desafios existentes ao desenvolvimento tecnológico é a construção de máquinas dotadas de inteligência que possam resolver problemas semelhante a como o cérebro humano o faria, o que constitui um objeto de estudo da área de Inteligência Computacional (ALEXANDRIA, 2005).

Assim, sabendo que a visão é o mais avançado dos nossos sentidos e que, possivelmente devido a este fato, a percepção humana seja baseada preponderantemente em imagens, parece natural que, a partir da Inteligência Computacional, haja surgido interesse na área de Visão Computacional. Esta área tem como propósito emular a visão humana, buscando, além de realizar medições e reconhecer padrões em imagens, fazer inferências e executar ações baseadas em entradas visuais, possibilitando a realização de tarefas complexas (HEIDJEN, 1994; ALEXANDRIA, 2005).

Sistemas de Visão Computacional são definidos como sistemas computadorizados capazes de adquirir, processar e interpretar imagens correspondentes a cenas reais (FILHO; NETO, 1999). Diferentemente do sistema de visão humano, outros tipos de radiações eletromagnéticas presentes em faixas não-visíveis do espectro, como infravermelho (mapas de temperatura), microondas (imagens de radar), raios-X (imagens médicas) e raios gama (medicina nuclear), ou mesmo outras modalidades de energia, como as presentes em campos magnéticos (tomografias) e ondas acústicas (ultrassons) podem ser utilizados como fonte por esses sistemas (HEIDJEN, 1994; GONZALEZ; WOODS, 2007).

Através da Visão Computacional, é possível evidenciar cenas microscópicas (detalhes de estruturas internas de um microprocessador) e macroscópicas (constelações a 15.000 anos luz de distância), cuja observação a olho nu seria impossível, e desempenhar tarefas de risco em que a presença humana seja prescindível, como a exploração do interior de vulcões, do fundo do mar, de outros planetas e de ambientes poluídos, como reatores atômicos (ALEXANDRIA, 2005).

Dentre os exemplos de aplicações do campo de Visão Computacional estão:

- sistemas de reconhecimento óptico de algarismos para medidores convencionais de energia (ALEXANDRIA, 2005);

- sistemas de visão computacional para a caracterização da grafita usando microfotografias (ALBUQUERQUE, 2007);
- análises comparativa de técnicas de detecção de movimento e rastreamento de objetos em vídeo digital usando dispositivos móveis (BARROS, 2010);
- e sistemas de rastreamento da mão humana utilizando visão artificial para aplicações embarcadas (FREITAS, 2011).

Outros trabalhos em PDI que podem ser destacados, estes relacionados, mais especificamente, a imagens biomédicas, e desenvolvidos no Grupo de Engenharia Biomédica da UFC são:

- *P-Snakes*: novo método de contornos ativos radiais usando energia hilbertiana para a segmentação do ventrículo esquerdo em imagens de ecocardiograma (ALEXANDRIA, 2011);
- técnica para segmentação automática de vias aéreas em imagens de tomografia computadorizada do tórax (CAVALCANTE, 2010);
- sistema de visão computacional para detecção e quantificação de enfisema pulmonar (FÉLIX, 2007); e
- e *MCA Crisp*: novo método de segmentação dos pulmões em imagens de TC baseado no método de contorno ativo (FILHO, 2010).

Visto isso, a seguir são apresentados alguns conceitos basilares em Processamento Digital de Imagens necessários para o estudo dos métodos utilizados.

2.1 Imagem Digital

Uma imagem pode ser matematicamente representada por uma função bidimensional $I(x, y)$ em que I é o nível de cinza do ponto de par ordenado (x, y) no plano xy . Imagem digital é aquela em que as coordenadas x e y são variáveis discretas e I assume uma quantidade finita de valores. Assim, a imagem digital é uma matriz finita cujos elementos, chamados de *pixels* (*picture elements* ou *pels*), possuem valor e localização particulares (GONZALEZ; WOODS, 2007).

A quantidade de tonalidades presentes na imagem depende do número de bits utilizados para quantizá-la. Por exemplo, utilizando-se n bits, há 2^n possíveis combinações de bits para representar um *pixel*, por conseguinte, 2^n diferentes níveis de tom de cinza.

Haja vista as imagens digitais serem representadas como matrizes, é possível aplicar-lhes transformações matemáticas convenientes à sua melhor utilização, como redução de ruído, suavização, iluminação, escurecimento, erosão, dilatação, realce, restauração e segmentação. O estudo destas transformações é de interesse do campo de Processamento Digital de Imagens, extensão do campo de Processamento Digital de Sinais.

Os métodos de Processamento Digital de Imagens possuem sua base de interesse em duas principais áreas de aplicação: uma busca o melhoramento da informação visual para a interpretação humana, a outra realiza o processamento de dados de imagens para armazenamento, transmissão e representação. A primeira área concentra-se em técnicas de ajuste de contraste, realce e restauração de imagens degradadas. A segunda, em procedimentos para identificar e extrair de uma imagem informação de interesse da forma mais adequada, para o reconhecimento de padrões, seja através de formas ou medidas (GONZALEZ; WOODS, 2007; FÉLIX, 2007).

Este trabalho concentra seu interesse precipuamente na segunda área.

2.2 Histograma

O histograma $h(n_c)$ de uma imagem $I(x, y)$ é o gráfico que representa a distribuição da quantidade de *pixels* ao longo dos níveis de cinza, dado por (GONZALEZ; WOODS, 2007)


$$h(n_c) = n_0, \quad (2.1)$$

em que n_0 é o número de *pixels* associados ao nível de cinza n_c . Estes níveis de cinza podem assumir diferentes faixas de valores, dependendo da quantidade de bits utilizados para representar a imagem. Por exemplo, para alguns tipos de imagem representadas por 8 bits, os *pixels* podem assumir valores de 0 a 255. É comum que o histograma seja normalizado pela quantidade total de *pixels*, passando a representar a frequência amostral de cada nível de cinza dos *pixels* da imagem, expressa por:

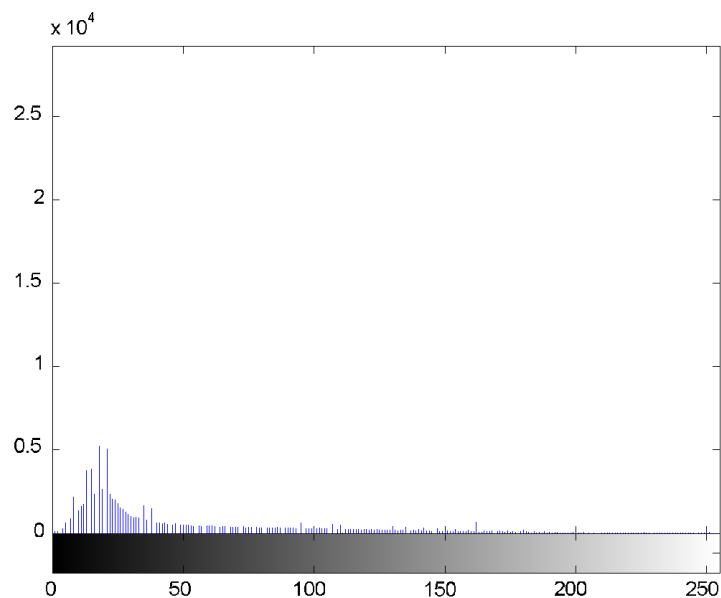
$$h_n = \frac{n_0}{n_t}, \quad (2.2)$$

em que n_t é a quantidade total de *pixels* presente na imagem.

Uma imagem típica de um ecocardiograma é mostrada na Figura 2.1 (a), em que o coração é representado verticalmente invertido devido ao posicionamento da sonda de ultrassom e o VE é a maior cavidade presente na imagem. O histograma dessa imagem é mostrado na Figura 2.1 (b).



(a)



(b)

Figura 2.1: exemplo de histograma de uma imagem; (a) imagem de ecocardiograma típica e (b) histograma de uma imagem de ecocardiograma típica.

O histograma é uma ferramenta que fornece uma descrição global da composição da imagem através de seus níveis de cinza. Este pode assumir a forma unimodal, caso a imagem apresente um único objeto, bimodal, se a imagem é constituída de duas regiões (objeto e fundo), ou, ainda, multimodal, quando há vários objetos na imagem. Assim, é comum que o conhecimento do histograma seja desejável se a etapa de limiarização, mencionada na seção seguinte, for necessária (GONZALEZ; WOODS, 2007).

2.3 Limiarização

A limiarização é uma operação simples que pode ser usada para realçar conjuntos de *pixels* que ocupem uma mesma faixa de intensidade de cinza em uma imagem (ALEXANDRIA, 2005).

Quando existe uma nítida diferença entre a intensidade de cinza em regiões do objeto e do fundo é comum que se atribuam diferentes rótulos a *pixels* que possuam valores que estejam acima ou abaixo de determinado limiar. Neste tipo de limiarização, como o resultado é uma imagem binária, o processo é denominado por binarização por limiar. A técnica de limiarização é muito utilizada na literatura devido às suas propriedades intuitivas, facilidade de implementação e baixo custo computacional (GONZALEZ; WOODS, 2007).

A operação de binarização por limiar sobre uma imagem $I(x, y)$ é definida como (GONZALEZ; WOODS, 2007)

$$I_b(x, y) = \begin{cases} 1, & \text{se } I(x, y) > L, \\ 0, & \text{caso contrário.} \end{cases}$$

em que I_b é a imagem binária resultante da operação e L é o limiar de binarização. Por exemplo, o histograma da imagem de raios-X na Figura 2.2 (a) é apresentado na Figura 2.3. Assim, as linhas verticais vermelhas presentes na escala de cinza da Figura 2.3 mostram os limiares de binarização a partir dos quais são obtidas as Figuras 2.2 (b) e 2.2 (c).

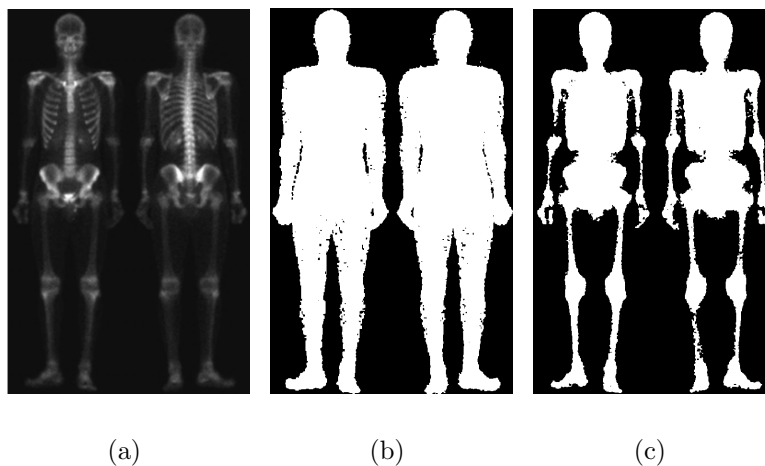


Figura 2.2: (a) imagem de raios-X original. (b) imagem de raios-X binarizada com limiar igual a 17 e (c) limiar igual a 27.




Figura 2.3: histograma da imagem 2.2 (a).

Analisando-se a imagem na Figura 2.1 (a) e seu histograma na Figura 2.1 (b), percebe-se que não é possível escolher um limiar tal que o VE e o resto da imagem não se sobreponham. Isso ocorre por que, no caso das imagens de ecocardiografia, o nível de cinza não é um atributo que consegue discriminar o VE e o fundo como duas classes isoladas. Portanto, conclui-se que uma binarização por limiar é inadequada para segmentar o ventrículo esquerdo em imagens de ecocardiografia.

2.4 Gradiente

Gradiente é um campo vetorial que aponta para a direção de maior taxa de crescimento do campo escalar sobre o qual é calculado. O gradiente $\nabla I(x, y)$ de uma imagem bidimensional $I(x, y)$ pode ser matematicamente expresso por

$$\nabla I(x, y) = \left[\frac{\partial I(x, y)}{\partial x}, \frac{\partial I(x, y)}{\partial y} \right] \quad (2.3)$$

em que $\frac{\partial I}{\partial u}$ é a derivada parcial de I em relação a certa variável u .

Outra medida importante é o módulo do gradiente, pois, além de ser uma grandeza escalar, possui a importante propriedade de invariância em relação à rotação do sistema de coordenadas, ou seja, isotropia. O módulo ou valor absoluto $|\nabla I(x, y)|$ do gradiente $\nabla I(x, y)$ é dado por

$$|\nabla I(x, y)| = \sqrt{\frac{\partial I(x, y)^2}{\partial x} + \frac{\partial I(x, y)^2}{\partial y}}. \quad (2.4)$$

O gradiente é um cálculo de diferenças infinitesimais que se reduz a um cálculo de diferenças finitas quando aplicado sobre imagens digitais. Se utilizado para medir diferenças entre as intensidades de tom de cinza de *pixels* adjacentes, este operador apresenta valores altos em regiões descontínuas da imagem. Assim, a partir de sua aplicação, podem ser identificadas mudanças locais nos níveis de cinza da imagem, evidenciando a presença de bordas. Por isto, as técnicas de detecção de bordas fazem uso de operadores diferenciais locais, como o gradiente.

Dentre as variações mais comuns de métodos para o cálculo do gradiente estão as máscaras de Prewitt e Sobel mostradas nas equações 2.5 e 2.6, respectivamente (PRATT, 2007).

$$M_{PREWITT_X} = \begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix}, M_{PREWITT_Y} = \begin{bmatrix} -1 & -1 & -1 \\ 0 & 0 & 0 \\ 1 & 1 & 1 \end{bmatrix}. \quad (2.5)$$

$$M_{SOBEL_X} = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}, M_{SOBEL_Y} = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix}. \quad (2.6)$$

Assim, as derivadas parciais presentes no gradiente podem ser aproximadas através de convoluções, denotadas pelo operador "∗", por:

$$\begin{aligned} \frac{\partial I(x, y)}{\partial x} &\cong I(x, y) * M_{PREWITT_X}, \\ \frac{\partial I(x, y)}{\partial y} &\cong I(x, y) * M_{PREWITT_Y}, \end{aligned} \quad (2.7)$$

utilizando as máscaras de Prewitt, ou por

$$\begin{aligned} \frac{\partial I(x, y)}{\partial x} &\cong I(x, y) * M_{SOBEL_X}, \\ \frac{\partial I(x, y)}{\partial y} &\cong I(x, y) * M_{SOBEL_Y}, \end{aligned} \quad (2.8)$$

utilizando as máscaras de Sobel. Estas aproximações visam reduzir o custo computacional do cálculo do gradiente.

2.5 Aquisição de Imagens e Pré-processamento

Ondas eletromagnéticas podem ser modeladas tanto como variações senoidais do campo eletromagnético quanto como um fluxo de partículas subatômicas viajando em um padrão ondulatório, em que cada partícula contém uma determinada quantidade de energia. A luz visível é um tipo particular de radiação eletromagnética que pode ser percebida pelo olho humano. De fato, as cores que percebemos representam uma faixa muito pequena do espectro eletromagnético (GONZALEZ; WOODS, 2007).

A luz visível, o infravermelho, as microondas, os raios-X, os raios gama, dentre outros, podem ser utilizados para a formação da imagem de entrada de um sistema de Visão Computacional. A aquisição de imagens consiste na captura dessas imagens, gerando uma matriz à qual podem ser aplicadas diversas operações (FREITAS, 2011). Esta aquisição pode ocorrer através de vários dispositivos, tais como *webcams*, câmeras de infra-vermelho, câmeras digitais, dentre outros (GONZALEZ; WOODS, 2007).

Este processo de conversão de uma cena real tridimensional em uma imagem bidimensional geralmente é realizado através de um arranjo de elementos sensores que reagem à modalidade de energia a ser detectada na cena. A resposta dos sensores são sinais elétricos que, amostrados e a quantizados, formam uma imagem digital. Um exemplo de dispositivo de aquisição de imagens é a câmera CCD (*Charge Coupled Device*), que consiste em uma matriz de células semicondutoras fotossensíveis que armazenam carga elétrica proporcional à energia luminosa incidente (FILHO; NETO, 1999; GONZALEZ; WOODS, 2007).

As imagens obtidas pelos dispositivos sensores na fase de aquisição tendem a apresentar uma degradação de sua qualidade pela introdução de ruído, deformação geométrica ou borramento devido ao movimento do objeto. A etapa de pré-processamento consiste na aplicação de métodos para melhorar a qualidade da imagem e reduzir as degradações introduzidas por estes elementos sensores (PITAS, 2000; FREITAS, 2011). Assim, algoritmos de pré-processamento são responsáveis principalmente pela filtragem de ruídos, realce e restauração de imagens (GONZALEZ; WOODS, 2007).

Os algoritmos que implementam as funções de PDI no pré-processamento dividem-se em dois grandes grupos: os que utilizam o domínio da frequência e os que utilizam

o domínio espacial (GONZALEZ; WOODS, 2007; ALEXANDRIA, 2005). Na primeira abordagem, informações globais da imagem obtidas, por exemplo, através da análise de Fourier são utilizadas para filtrar frequências portadoras de ruído, realçar detalhes ou recuperar degradações causadas por fenômenos conhecidos. Na segunda abordagem, essas operações são realizadas utilizando-se propriedades locais dos *pixels* sem que haja necessidade de um mapeamento para outro domínio.

Além dessa classificação, a etapa de pré-processamento pode ser realizada, principalmente, por dois tipos de técnicas: restauração e realce. As técnicas de restauração preocupam-se principalmente com a reconstrução ou recuperação de imagens degradadas, sendo desejável um conhecimento prévio sobre o fenômeno de degradação. Por outro lado, as técnicas de realce melhoram a qualidade subjetiva das imagens, aguçando-lhes determinados atributos e reduzindo o ruído (GONZALEZ; WOODS, 2007; FREITAS, 2011).

Comumente, em sistemas de Visão Computacional, o pré-processamento é uma etapa preliminar à segmentação.

2.6 Segmentação

A segmentação de imagens é um dos principais processos constituintes de um sistema de Visão Computacional, sendo utilizada para separar determinado objeto ou região de interesse do restante da imagem à qual pertence. Para tanto, a imagem deve ser particionada em regiões disjuntas de características similares (ALEXANDRIA, 2005; FÉLIX, 2007; FILHO, 2010). Esse particionamento é realizado avaliando-se propriedades dos *pixels* como localização, intensidade, textura, etc. Por exemplo, para o caso da análise em terra de imagens de satélite, uma propriedade significativa para a segmentação é a cor (GONZALEZ; WOODS, 2007).

Os critérios de avaliação mais utilizados para rotular *pixels* como pertencentes ou não a determinada região ou objeto são a similaridade e a descontinuidade. A primeira abordagem, utilizada na segmentação orientada por regiões, consiste em agrupar *pixels* com propriedades aproximadamente iguais, particionando a imagem em regiões similares sob determinados critérios (GONZALEZ; WOODS, 2007). Na segunda abordagem, a determinação destas regiões é baseada em mudanças abruptas nas propriedades dos *pixels*, segmentando-se a imagem através da detecção de bordas.

Considera-se borda um conjunto de *pixels* conectados sobre uma interface entre duas regiões disjuntas. A identificação de uma borda requer a habilidade de mensurar transições

de tons de cinza significativas (GONZALEZ; WOODS, 2007). Então, na detecção de bordas, a relevância no critério de escolha das regiões constituintes da imagem está na descontinuidade entre as propriedades dos *pixels* adjacentes. Desta forma, são tomados como pertencentes a uma mesma região, *pixels* que se encontrem dentro de uma mesma borda. Podem ser citados como exemplo de segmentação que utiliza detecção de bordas os MCAs tradicionais.

Ao contrário da segmentação por detecção de bordas, que subdivide a imagem através da identificação dos limites entre as regiões de interesse, a segmentação por regiões encontra as mesmas diretamente, utilizando a similaridade entre propriedades pré-determinadas dos *pixels*. A segmentação por regiões pode ser considerada finalizada quando são satisfeitas as seguintes condições (GONZALEZ; WOODS, 2007):

- todos os *pixels* se encontram em alguma região;
- as regiões são conectadas segundo um critério pré-definido;
- as regiões são disjuntas, não havendo intersecções entre estas;
- em cada região, o critério pré-definido é obedecido por todos os *pixels*;
- as regiões possuem propriedades diferentes segundo o critério utilizado.

São exemplos de segmentação orientada por regiões os métodos de crescimento de regiões, *split-merge*, segmentação por limiarização e segmentação *watershed* (GONZALEZ; WOODS, 2007).

Em ambas as abordagens apresentadas, o nível de subdivisão da imagem depende do problema a ser resolvido, devendo a segmentação ser finalizada quando os elementos de interesse são isolados. Assim, é desnecessário que o nível de detalhe da segmentação ultrapasse o requerido para identificar esses elementos (GONZALEZ; WOODS, 2007).

De maneira geral, a segmentação é um pré-requisito de preparação da imagem para extração de atributos e classificação, sendo uma das tarefas mais complexas em PDI no caso de imagens ruidosas ou com pouco contraste.

Algoritmos de segmentação de imagens podem ser classificados como manuais, semi-automáticos e automáticos. Nos algoritmos manuais, a segmentação é efetuada inteiramente por um operador humano. Nos algoritmos de segmentação semi-automática, o operador humano fornece apenas pontos característicos da estrutura a ser segmentada ou delimita a região onde a mesma é encontrada. Na segmentação automática, comumente a

intervenção humana é reservada apenas para eventuais correções da segmentação obtida por meio de um algoritmo autônomo (FILHO C.; MOURA, 1999; JÚNIOR, 2010).

Uma classe de algoritmos que possibilita a segmentação semi-automática e automática para propósitos gerais são os métodos de contornos ativos, pertencentes a um conjunto de algoritmos chamado de contornos deformáveis (BOUHOURS, 2006; ALEXANDRIA et al., 2011).

2.7 Contornos Ativos

O modelo de contornos ativos, também conhecido como *snakes*, foi inicialmente idealizado por Kass, Witkin e Terzopoulos (KASS; WITKIN; TERZOPOULOS, 1988) como uma curva fechada matematicamente definida por pontos de controle chamados de nós. A ligação destes nós forma um contorno deformável que, sob influência de algumas forças, deve ajustar-se às bordas da região da imagem que se deseja segmentar. Tal objetivo pode ser alcançado através da busca constante dos nós por uma região adjacente de menor energia. Assim, os contornos em questão são ditos ativos devido ao fato de os dados se atualizarem a cada vez que os nós se movem, minimizando dinamicamente uma dada função de energia. É comum que a localização dos nós seja estipulada manualmente, traçando-se um polígono dentro ou em torno da região de interesse, o que exige algum conhecimento *a priori* da imagem.

Inicialmente o MCA foi utilizado como um segmentador de propósito geral, sendo aplicado principalmente em detecção de movimento e visão estéreo (KASS; WITKIN; TERZOPOULOS, 1988). Posteriormente é aplicado na resolução de diversos problemas de Visão Computacional, abrangendo áreas como: Segurança (LOPES, 2003), Materiais para Construção Mecânica (COSTA, 2008), auxílio ao diagnóstico médico (ITAI Y.; KIM, 2007), Reconhecimento de Padrões (CHEN et al., 2008), entre outras (FILHO, 2010).

Atualmente os contornos ativos ou *snakes* têm sido empregados, inclusive, como no caso deste trabalho, para segmentação das paredes do miocárdio. Tal segmentação constitui um pré-requisito a partir do qual informações sobre os valores de volume do VE e fração de ejeção podem ser calculadas (YEZZI, 1997; ALEXANDRIA et al., 2011; FELIX et al., 2011).

Há muitas variações do MCA original encontradas na bibliografia, dentre as quais pode-se citar:

- *Genetic Snakes* (MACEACHERN; MANKU, 1998);

- *GVF Snakes* (XU; PRINCE, 1998);
- *T-snakes* (MCINERNEY; TERZOPOULOS, 1999); e
- *Snakes Radiais* (DENZLER; NIEMANN, 1996; ALEXANDRIA, 2011).

Em sua idealização original, os contornos ativos (KASS; WITKIN; TERZOPOULOS, 1988) são representados explicitamente como curvas parametrizadas em uma formulação Lagrangiana, em que a definição do contorno é feita através de um parâmetro que identifica cada um de seus pontos, daí o fato de também serem chamados de contorno ativos paramétricos. Todavia, a partir de algumas análises (KICHENASSAMY et al., 1995), é possível concluir que existe uma série de problemas associados a esta abordagem. Um desses problemas é a dificuldade do algoritmo de encontrar uma solução sub-ótima em topologias nas quais existem múltiplos mínimos. Além disso, a estrutura de interesse deve ser previamente conhecida, pois este modelo é incapaz de executar alterações em sua topologia sem processamento adicional. Desse modo, existe a necessidade de uma reparametrização do contorno para que o mesmo possa se dividir ou se unificar. Outras limitações do MCA tradicional são a grande dependência da inicialização e a dificuldade de segmentar regiões côncavas e convexas, devidas ao atrelamento dos critérios de otimização à parametrização (MCINERNEY; TERZOPOULOS, 1996).

Estas dificuldades podem ser superadas por uma outra classe de algoritmos de contornos deformáveis chamada de contornos ativos geométricos ou geodésicos, implementados através do método level-set. Contornos ativos geodésicos recebem esta nomenclatura, pois, diferentemente de como ocorre nos *snakes* tradicionais, os contornos são definidos implicitamente como curvas geodésicas de uma topologia pré-existente (OSHER; SETHIAN, 1988).

Os contornos ativos geométricos são representados por curvas de nível de uma função de maior dimensionalidade, partindo de uma formulação Euleriana (XU; YEZZI; PRINCE, 2000). Esta formulação confere ao método maior robustez na presença múltiplos mínimos locais causados por ruído ou degradação em relação aos *snakes* tradicionais. Além disso, é criada a possibilidade de que o contorno se divida ou se unifique naturalmente, já que o mesmo não é parametrizado. Outra vantagem de tal abordagem é que os procedimentos e cálculos permanecem válidos para qualquer número de dimensões espaciais, sendo diretamente análogos de uma dimensão para outra. Por exemplo, os cálculos que descrevem a evolução de uma superfície fechada tridimensional são análogos aos que descrevem a evolução de uma frente propagante fechada bidimensional.

2.8 Frentes Propagantes

Frentes propagantes são padrões matemáticos que ocorrem na modelagem de diversos fenômenos. Como entidades físicas que exemplificam essas frentes podem ser citadas as ondas oceânicas, os incêndios na vegetação e as bordas de manchas de óleo na água. Idealiza-se uma frente propagante como uma hipersuperfície fechada e sem cruzamentos que flui através de seu campo gradiente (SETHIAN, 1990).

Analisando a propagação da chama em um gás inflamável, e o crescimento de cristais de gelo em um líquido resfriado, *Markstein* (MARKSTEIN, 1951) e *Langer* (LANGER, 1980), respectivamente, observaram que a propagação dessas frentes possui dependência com sua curvatura. No caso da chama, por exemplo, a velocidade de propagação $F(K)$, em quaisquer pontos dessa frente, possui dependência com sua curvatura nestes pontos, obedecendo à relação

$$F(K) \propto 1 - \epsilon K, \quad (2.9)$$

em que ϵ é uma constante e K sua curvatura.

Em Processamento Digital de Imagens, frentes propagantes podem ter uma utilização vantajosa na delimitação de regiões da imagem com propriedades semelhantes. Nesse contexto, as frentes devem aproximar um contorno, ou seja, uma interface entre regiões descontínuas da cena representada na imagem. Para segmentação de objetos em imagens digitais, a dependência entre a curvatura do contorno e sua velocidade de propagação é uma característica desejável, pois, assim como nos fenômenos físicos referenciados, diminui o efeito de perturbações ao longo do tempo. Esta propriedade evita que o contorno adquira um comportamento instável e conduza o método a uma segmentação falha.

Na formulação Euleriana do método *level-set*, uma frente pode ser representada de maneira intrínseca por uma hipersuperfície de nível de outra hipersuperfície de maior dimensionalidade. Essa abordagem, além de possuir a vantagem de prescindir de uma representação explícita dos pontos do contorno em termos das coordenadas espaciais, incorpora ao método *level-set* a estabilidade inerente às frentes propagantes.

Feitas as considerações a respeito do levantamento do estado da arte, procede-se à explanação mais detalhada dos métodos utilizados.

Capítulo 3

Método *Level-Set* Orientado por Gradiente

Inicialmente idealizado por *Stanley Osher* e *James Sethian*, o método *level-set* é capaz de representar matematicamente a interface de uma região no espaço e descrever precisamente seu comportamento futuro sem que seja necessária a identificação explícita de seus pontos. Esta abordagem é utilizada em segmentação de imagens para representar um contorno deformável que se ajuste às bordas dos objetos em cena (OSHER; SETHIAN, 1988).

O método *level-set* consiste em uma frente propagante representada por uma curva fechada e sem cruzamentos ϕ . Esta curva é definida implicitamente como o lugar geométrico onde uma função de maior dimensionalidade ψ assume um valor constante igual a 0, ou seja, (SETHIAN, 1990)

$$\psi(\mathbf{x}, t) = 0, \quad (3.1)$$

em que \mathbf{x} é o vetor posição (x, y) e t o instante de tempo. Uma superfície e sua curva geodésica que representa a frente propagante no método *level-set* são mostradas na Figura 4.1.

Inicialmente considera-se $\phi(\mathbf{x}, 0)$ como a curva de nível $\psi(\mathbf{x}, 0) = 0$ e $\frac{\partial \mathbf{x}}{\partial u}$ como a derivada parcial de \mathbf{x} em relação a certa variável u . Desta forma, sendo $\mathbf{n} = \frac{\nabla \psi}{|\nabla \psi|}$ o vetor unitário normal ao contorno $\phi(\mathbf{x}, t)$ no ponto localizado por \mathbf{x} , a componente do vetor velocidade F normal ao contorno é dada por $F(\mathbf{x}, t) = \frac{\partial \mathbf{x}}{\partial t} \mathbf{n}$. Então, tomando-se a derivada temporal da equação 3.1, tem-se (SETHIAN, 1990)

$$\frac{\partial \psi}{\partial t} + F|\nabla \psi| = 0, \quad (3.2)$$




Figura 3.1: curva de contorno (em vermelho) da superfície no nível 0.

em que ∇ é o operador gradiente. Esta equação diferencial parcial é chamada de equação do movimento da frente e, em um espaço vetorial discretizado $i \times j$, pode ser escrita recursivamente como (SETHIAN, 1996)

$$\frac{\psi_{ij}^{n+1} - \psi_{ij}^n}{\Delta t} + (F_{ij})|\nabla\psi_{ij}^n| = 0, \quad (3.3)$$

em que ψ_{ij}^n descreve a superfície ψ nas coordenadas cartesianas (i, j) e no instante de tempo n , sendo Δt o passo utilizado para o tempo.

3.1 Aproximação Numérica

A equação 3.2 raramente possui uma solução analítica, fazendo-se necessário o uso de equações recursivas e métodos numéricos. Como na equação 3.3 está presente um termo de gradiente, existe a necessidade de calcular derivadas. Um método simples de aproximar uma derivada é o das diferenças centrais (SETHIAN, 1990)

$$\frac{df}{d\lambda} \approx \frac{f_{k+1} - f_{k-1}}{2\Delta k}, \quad (3.4)$$

em que k é o índice do k -ésimo ponto de discretização de λ e Δk é a diferença entre um índice k e seu antecessor. Todavia, este método produz pequenos erros de aproximação em alguns pontos críticos que, ao longo das iterações, propagam-se em torno de suas adjacências. Deste modo, mesmo para condições iniciais suaves, as oscilações geradas recursivamente pelo método das diferenças centrais podem se tornar instáveis, fazendo com que o mesmo forneça respostas imprevisíveis. Estas distorções que surgem depois de algumas iterações do algoritmo são ilustradas pela Figura 3.2. Desta forma, nota-se que o método das diferenças finitas não aproxima corretamente o movimento analítico da frente, havendo a necessidade de outro método que obedeça a certas condições de estabilidade.




Figura 3.2: distorções causadas pela propagação do erro (frente inicial em azul).

Então, seja $\psi(\mathbf{x}, t)$ a solução da equação do movimento cuja velocidade F possui dependência à curvatura, conforme previsto por *Markstein* na equação 2.9 (MARKSTEIN, 1951). Seja, ainda, $\psi_\epsilon(\mathbf{x}, t)$ outra solução da equação do movimento, porém cuja dependência de F à curvatura seja infinitesimalmente pequena, ou seja,

$$\psi_\epsilon(\mathbf{x}, t) = \lim_{\epsilon \rightarrow 0} \psi(\mathbf{x}, t). \quad (3.5)$$

Um método de aproximação numérica é dito em obediência à condição de estabilidade se, para uma velocidade $F = 1$, independente da curvatura, este fornece uma solução para a equação do movimento igual a ψ_ϵ , ou seja,

$$\lim_{\epsilon \rightarrow 0} \psi(x, t) = \psi(x, t)|_{\epsilon=0}. \quad (3.6)$$

Em outras palavras, um método numérico que garante estabilidade ao modelo é aquele que limita o movimento de uma frente independente da curvatura ao de uma frente minimamente dependente da mesma para qualquer instante de tempo. Isto significa que as variações no contorno estão limitadas a níveis que mantenham sua previsibilidade (SETHIAN, 1996).

Segue que, diferenciando-se a equação 3.2 em relação a x em um sistema de apenas uma coordenada espacial, a equação do movimento é reescrita em termos da derivada de ψ , $u = \frac{\partial \psi}{\partial x}$, como uma equação de *Hamilton-Jacobi* (SETHIAN, 1990),

$$\frac{\partial u}{\partial t} + \frac{\partial H(u)}{\partial x} = 0, \quad (3.7)$$

em que H é uma função de u e da velocidade F chamada de Hamiltoniano. Esta notação é conveniente devido ao fato de que a equação do movimento é reduzida a uma forma já conhecida como lei de conservação hiperbólica. Esta equação descreve, dentre outros fenômenos, o movimento de um fluido compressível. Deste modo, um método numérico que obedece à condição de estabilidade da lei de conservação hiperbólica também obedece a esta condição para o movimento de uma frente propagante (SETHIAN, 1996).

Nesse sentido, discretiza-se a equação 3.7 utilizando-se três pontos como (SETHIAN, 1990)

$$\frac{u_i^{n+1} - u_i^n}{\Delta t} = - \frac{h(u_i^n, u_{i+1}^n) - h(u_{i-1}^n, u_i^n)}{\Delta x}, \quad (3.8)$$

em que $h(u_i^n, u_{i+1}^n)$ é o fluxo numérico que aproxima o Hamiltoniano H entre os pontos i e $i + 1$ na n -ésima iteração. Para que esta aproximação esteja em conformidade com a condição imposta para que haja estabilidade, deve-se escolher um método adequado para calcular o fluxo numérico h . Dentre as várias técnicas utilizadas na literatura para aproximar equações de *Hamilton-Jacobi*, como, por exemplo, o método de *Lax-Friedrich* (QIAN, 2003), o método de *Engquist-Osher* é escolhido devido a sua simplicidade. Assim, tem-se que (ENGQUIST B.; OSHER, 1980)

$$h(u_1, u_2) = [\max(u_1, 0)^2 + \min(u_2, 0)^2]^{\frac{1}{2}}, \quad (3.9)$$

em que $h(u_1, u_2)$ é o fluxo numérico que aproxima o Hamiltoniano H no ponto médio entre os pontos 1 e 2. Integrando-se a equação 3.2 em relação à variável x tem-se que

$$\frac{\partial \psi}{\partial t} + [H(u)] = 0. \quad (3.10)$$

Então, discretizando-se o resultado, obtém-se uma equação recursiva para o movimento da frente, dada por

$$\psi_i^{n+1} = \psi_i^n - H(u_i) \Delta t. \quad (3.11)$$

Para se obter um método numérico estável que descreva o movimento da frente, aproxima-se o Hamiltoniano $H(u_i)$ pelo fluxo numérico $h(u_-, u_+)$ utilizando-se a equação 3.9. Os termos u_- e u_+ são aproximações das derivadas espaciais de ψ calculadas utilizando-se pontos vizinhos de i através das diferenças finitas

$$u_+ = \frac{\psi_{i+1} - \psi_i}{\Delta x}, u_- = \frac{\psi_i - \psi_{i-1}}{\Delta x}. \quad (3.12)$$

Após a substituição, finalmente obtém-se (SETHIAN, 1996)

$$\psi_i^{n+1} = \psi_i^n - \Delta t [\max(\frac{\psi_i^n - \psi_{i-1}^n}{\Delta x}, 0)^2 + \min(\frac{\psi_{i+1}^n - \psi_i^n}{\Delta x}, 0)^2]^{\frac{1}{2}}. \quad (3.13)$$

Como as derivações anteriores são obtidas apenas para uma dimensão espacial, são escritas as equações análogas para frentes bidimensionais (SETHIAN, 1996)

$$\psi_{ij}^{n+1} = \psi_{ij}^n - h(u_{ij}^{i-}, u_{ij}^{i+}, v_{ij}^{j-}, v_{ij}^{j+})\Delta t, \quad (3.14)$$

em que

$$u_{ij}^{i-} = \frac{\psi_{i,j}^n - \psi_{i-1,j}^n}{\Delta x}, u_{ij}^{i+} = \frac{\psi_{i+1,j}^n - \psi_{i,j}^n}{\Delta x}, \quad (3.15)$$

$$v_{ij}^{j-} = \frac{\psi_{i,j}^n - \psi_{i,j-1}^n}{\Delta y}, v_{ij}^{j+} = \frac{\psi_{i,j+1}^n - \psi_{i,j}^n}{\Delta y}. \quad (3.16)$$

Para gerar a frente computacionalmente, incorpora-se a velocidade F juntamente com a curvatura K ao modelo numérico através da equação 2.9, obtendo-se a equação 3.17

$$\psi_{ij}^{n+1} = \psi_{ij}^n + [\max(F_{ij}, 0)\nabla^+ + \min(F_{ij}, 0)\nabla^-]\Delta t, \quad (3.17)$$

em que

$$\nabla^+ = [\max(u_{ij}^{i-}, 0)^2 + \min(u_{ij}^{i+}, 0)^2 + \max(v_{ij}^{j-}, 0)^2 + \min(v_{ij}^{j+}, 0)^2]^{\frac{1}{2}}, \quad (3.18)$$

$$\nabla^- = [\max(u_{ij}^{i+}, 0)^2 + \min(u_{ij}^{i-}, 0)^2 + \max(v_{ij}^{j+}, 0)^2 + \min(v_{ij}^{j-}, 0)^2]^{\frac{1}{2}}, \quad (3.19)$$

sendo ∇^+ e ∇^- aproximações locais do gradiente. Neste caso, a curvatura é aproximada através do cálculo

$$K = \nabla \cdot \frac{\nabla \psi}{|\nabla \psi|} = \frac{\frac{\partial^2 \psi}{\partial x^2} \frac{\partial \psi}{\partial y} - 2 \frac{\partial \psi}{\partial x} \frac{\partial \psi}{\partial y} \frac{\partial \psi}{\partial x y} + \frac{\partial^2 \psi}{\partial y^2} \frac{\partial \psi}{\partial x}}{\frac{\partial \psi}{\partial x}^2 + \frac{\partial \psi}{\partial y}^2}, \quad (3.20)$$

em que as derivadas parciais são substituídas por diferenças finitas para trás.

A modelagem matemática apresentada é capaz de descrever com acurácia o movimento de uma frente propagante cujo comportamento é previsível para um intervalo de tempo arbitrariamente longo, se a frente inicial é fechada e sem cruzamentos. Para que tal modelagem possua utilidade em segmentação de imagens, é necessário que a imagem através da qual a frente se propaga exerça influência em seu movimento. Sendo assim, é desejável que esta frente diminua gradualmente sua velocidade, cessando seu movimento ao alcançar bordas de objetos presentes na imagem. Para isto, é introduzido ao modelo existente um termo de velocidade U que deve possuir valores baixos em regiões onde o movimento do contorno deva parar. A equação do movimento que incorpora esse termo é dada por

$$\psi_{ij}^{n+1} = \psi_{ij}^n - U_{ij}H_{ij}\Delta t \quad (3.21)$$

, em que i e j são os índices dos elementos das matrizes ψ , H e U .

Todavia, encontrar um termo de velocidade U que estacione o contorno sobre as bordas dos objetos de uma imagem exige algum conhecimento *a priori* a respeito da mesma. Assim, a escolha adequada de um termo de velocidade pode variar, dependendo da imagem a ser segmentada, sendo tal escolha definida para cada tipo de imagem testada.

3.2 Ajuste de Parâmetros

Por possuir uma formulação matemática complexa em relação aos métodos tradicionais ou paramétricos, o método *level-set* demanda maior esforço no ajuste de seus parâmetros. Os parâmetros que regulam o movimento da frente no método *level-set* orientado por gradiente independentemente da imagem são: o passo de tempo Δt , os passos de espaço Δx e Δy e o coeficiente de curvatura ϵ .

O passo de tempo Δt define o quanto a função *level-set* ψ deve se mover por iteração, regulando a velocidade de propagação da frente. A diminuição do valor de Δt torna o movimento da frente lento, por outro lado, seu aumento pode levar a frente a ignorar restrições impostas pelo termo U_{ij} . Para Δx e Δy , a regra geral é que, quanto menor o passo, mais rápida a propagação do contorno. No entanto, novamente, precauções devem ser tomadas, pois contornos rápidos tendem a transgredir os limites das bordas dos objetos. Por último, o coeficiente de curvatura ϵ é um número real pertencente ao intervalo $[0, 1]$ que indica o grau de influência da curvatura do contorno sobre a velocidade do mesmo, de modo que $\epsilon = 1$ indica a influência máxima e $\epsilon = 0$ indica independência da velocidade em relação à curvatura. As Figuras 3.3 (a) e 3.3 (b) ilustram como a variação de ϵ modifica o comportamento da frente inicial, fazendo com que pontos onde a curvatura seja baixa se movimentem mais rapidamente. Conforme o valor de ϵ aumenta, mais suave se torna a frente, tendendo a se tornar uma circunferência para uma quantidade arbitrariamente grande de iterações.

3.3 Inicialização

Um quesito ainda não esclarecido a respeito do método *level-set* é o valor inicial da equação do movimento, ou seja, $\psi(x, y, 0)$. O contorno é inicializado como a interpolação




Figura 3.3: influência da curvatura do contorno sobre a velocidade (contorno inicial azul e no interior); (a) $\epsilon = 0$ e (b) $\epsilon = 0,25$.

de vértices de um polígono que são pontos indicados na imagem manual ou automaticamente. Deste modo, a função $\psi(x, y, 0)$ assume valores constantes negativos quando o ponto (x, y) está dentro do polígono e valores constantes positivos quando o ponto (x, y) está fora do mesmo. Então, o contorno ϕ é definido como o conjunto de pontos no plano xy onde ψ é nulo. Como, conforme esta inicialização, não há pontos em que ψ assumam valores nulos, o contorno ϕ é aproximado como o conjunto de pontos em que a interpolação de ψ sobre o plano xy é nula. Portanto, o contorno $\phi(x, y)$ aproxima a curva de nível $\psi(x, y, 0) = 0$, conforme prevê o modelo.

A inicialização do método *level-set* orientado por gradiente é ilustrada na Figura 3.4



Figura 3.4: inicialização do método *level-set* orientado por gradiente.

3.4 Filtragem do Hamiltoniano

Uma das contribuições propostas neste trabalho é a filtragem do Hamiltoniano, utilizado no método *level-set* orientado por gradiente. Como explicado na seção anterior, a função *level-set* inicial $\psi(x, y, 0)$ possui um formato de prisma no espaço, assumindo valores positivos dentro dos limites de um polígono e valores negativos fora deste. Analisando-se por meio de testes o funcionamento básico do método *level-set* orientado por gradiente, é possível perceber que o Hamiltoniano H , presente na equação 3.11, só possui valores significativos nas proximidades da frente inicial, ou seja, próximo à curva de nível $\psi(x, y) \approx 0$. Isto ocorre por que, quando o gráfico da função $\psi(x, y)$ possui tal formato, esta só apresenta variação nas regiões próximas às arestas do polígono que representa o contorno. Deste modo, a superfície $\psi(x, y)$ só pode se movimentar para cima ou para baixo nestas regiões, permanecendo a curva de nível $\psi(x, y) \approx 0$ praticamente no mesmo lugar não obstante a função *level-set* se alterar.

Para contornar esse problema, é proposta, neste trabalho, a filtragem do Hamiltoniano H por uma janela gaussiana $n \times n$ de média nula e desvio-padrão σ definida por $G_{n \times n}(\sigma)$. O efeito da filtragem é a difusão por uma maior vizinhança da área dentro da qual o contorno pode se expandir, aumentando sua velocidade.

Um aumento no valor de n produz um correspondente aumento na velocidade do contorno, o qual, todavia, pode ignorar detalhes da imagem que possuam alguns *pixels* a menos que a janela. Assim, na definição do tamanho n da janela gaussiana, deve ser considerado o tamanho mínimo dos detalhes a serem detectados na imagem, não devendo n exceder esse valor. A escolha do desvio-padrão σ a ser utilizado deve ser feita em observância ao tamanho da janela, respeitando o compromisso existente entre o desempenho do método e o nível de detalhamento da segmentação. Como os parâmetros n e σ são escolhidos de modo heurístico, métodos de busca de valores ótimos para esses parâmetros podem ser abordados em trabalhos futuros.

3.5 Função Sinal

Outra contribuição proposta neste trabalho é a introdução de uma função sinal ao método *level-set*. Na formulação de tal método não existe mecanismo algum que controle a expansão ou contração do contorno. Como afirmado na seção 3.2, contornos rápidos tendem a sobrepular os limites impostos pelo termo de velocidade, atravessando bordas sobre as quais deveriam permanecer inertes ocasionalmente. Dessa forma, o contorno

pode se expandir em regiões onde deveria se contrair e vice-versa. Então, propõe-se como contribuição uma possível solução para essa dificuldade.

Sabendo-se que, conforme exposto na seção 2.6, um dos atributos capazes de identificar objetos em imagens é o nível de cinza, é possível realizar esta tarefa associando o sentido do movimento da frente ao valor de intensidade dos *pixels* em cada ponto da imagem. Para isso é criada uma função sinal S . Esta função assume o valor -1, em pontos onde a imagem possui nível de cinza tipicamente do fundo, e +1, em pontos onde a imagem possui nível de cinza tipicamente do objeto. Assim, propõe-se uma função sinal S a ser incorporada no modelo através do cálculo das derivadas dadas por

$$u_{ij}^{i-} = S_{ij} \frac{\psi_{i,j}^n - \psi_{i-1,j}^n}{\Delta x}, \quad (3.22)$$

$$u_{ij}^{i+} = S_{ij} \frac{\psi_{i+1,j}^n - \psi_{i,j}^n}{\Delta x}, \quad (3.23)$$

$$v_{ij}^{j-} = S_{ij} \frac{\psi_{i,j}^n - \psi_{i,j-1}^n}{\Delta y}, \quad (3.24)$$

$$v_{ij}^{j+} = S_{ij} \frac{\psi_{i,j+1}^n - \psi_{i,j}^n}{\Delta y}. \quad (3.25)$$

Além disso, o termo S deve, também, ser multiplicado elemento a elemento por U_{ij} na equação 3.21.

A função sinal fornece grande flexibilidade na inicialização se há pouca superposição entre os níveis de cinza de fundo e objeto. Como não é esse o caso em imagens de ecocardiografia, neste trabalho a função sinal é substituída por um escalar s que assume valor -1 se a frente se contrai e +1 se a frente se expande.

Desse modo, o método *level-set* orientado por gradiente é implementado computacionalmente e aplicado em imagens sintéticas e de ecocardiografia. Explana-se, a seguir, a respeito de outro método *level-set* que utiliza informações comuns a certas regiões da imagem para segmentá-la, o método *level-set* orientado por regiões.

Capítulo 4

Método *Level-Set* Orientado por Regiões

Os contornos ativos que compõem predominantemente a literatura atual podem ser classificados como orientados por bordas ou orientados por regiões. Os modelos baseados em bordas usam a informação local das bordas do objeto para atrair o contorno ativo até as mesmas. Por outro lado, contornos ativos baseados em regiões, como é o caso dos *Piecewise Constant (PC) Models* (CHAN; VESE, 2001), utilizam informações de intensidade das regiões de interesse para guiar os contornos ativos até suas bordas. Estes últimos, todavia, geralmente partem da premissa de que esta intensidade nas regiões de interesse são estatisticamente homogêneas, ou seja, a grosso modo, constantes.

No entanto, em imagens não sintéticas, como é o caso de imagens extraídas de exames de ecocardiografia, a ausência de homogeneidade, mesmo em regiões pertencentes ao mesmo objeto, não é uma característica incomum, fato que aumenta a complexidade da segmentação. No sentido de superar tais dificuldades foi proposto por *Li et al.* (2008) um contorno ativo baseado em regiões que permite utilizar informações locais de intensidade da imagem em uma vizinhança de tamanho regulável. Estas informações são utilizadas para criar duas funções, uma dentro e uma fora do contorno, que tentam aproximar localmente a imagem. Então, um funcional de energia é definido a partir do erro entre as duas aproximações e a imagem real e incorporada ao método *level-set*. O critério de otimização do método *level-set* consiste na minimização dessa energia funcional, que deve decair no tempo conforme o contorno ativo se ajuste às bordas dos objetos.

4.1 Fundamentação Teórica

Seja o caso particular de uma imagem I definida sobre o domínio x composta por apenas duas regiões disjuntas e separadas por uma curva C sem cruzamentos. Para aproximar a curva que delimita as duas regiões da imagem, foi proposto um contorno ativo que pode ser obtido a partir da minimização do funcional de energia E_{CV} (CHAN; VESE, 2001)

$$E_{CV} = \lambda_1 \int_{C_1} |I(x) - c_1|^2 dx + \lambda_2 \int_{C_2} |I(x) - c_2|^2 dx + \nu |C|, \quad (4.1)$$

em que λ_1 , λ_2 e ν são constantes que regulam o grau de contribuição de cada parcela na contabilização total da energia, enquanto C_1 e C_2 representam as regiões fora e dentro do contorno, respectivamente. As constantes c_1 e c_2 são aproximações da intensidade da imagem, respectivamente, fora e dentro do contorno, sendo calculadas através da média do nível de cinza da imagem nessas regiões.

As duas integrais presentes na equação 4.1 são, respectivamente, os erros médios quadráticos das aproximações c_1 e c_2 em relação à imagem nas regiões C_1 e C_2 . Estes termos são responsáveis conjuntamente por um aumento na energia enquanto persistirem erros de aproximação, guiando o contorno para a direção contrária ao aumento do erro. O termo $\nu |C|$, em que $|C|$ é a definição do comprimento do contorno, tem por objetivo punir contornos de grande comprimento, causando assim sua diminuição. O efeito da minimização do funcional de energia, bem como de suas parcelas individualmente é mostrado na Figura 4.1.

Todavia, como mencionado, devido à não homogeneidade da intensidade dos *pixels* nas regiões de interesse, em muitas imagens o modelo ora descrito se torna simplista para fins de segmentação. Isso ocorre porque as médias locais c_1 e c_2 não conseguem aproximar com acurácia a imagem nas regiões C_1 e C_2 . Desse modo é necessária uma abordagem que considere as variações de intensidade de cinza dentro de uma mesma região. Tais variações são representadas pelas funções f_1 e f_2 no modelo *Region-Scalable (RS) Fitting* dado por (LI et al., 2008)

$$E_{local}(x) = \sum_{i=1}^2 \lambda_i \int_{C_i} G_\sigma(x - y) |I(y) - f_i(x)|^2 dy, \quad (4.2)$$

em que y é o centro do núcleo gaussiano de média nula e desvio padrão σ ,

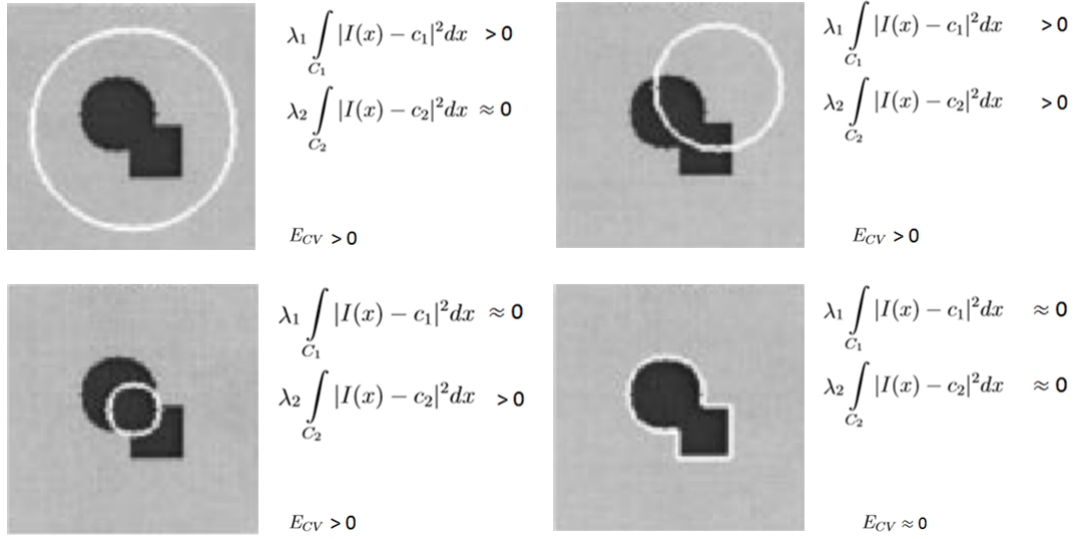


Figura 4.1: efeitos no contorno da variação das integrais presentes no funcional de energia (equação 4.1).

$$G_\sigma(u) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{u^2}{2\sigma^2}}. \quad (4.3)$$

As funções f_1 e f_2 devem ser aproximações suaves da imagem dentro e fora do contorno C , respectivamente. Além disso, o nível de influência dos erros de aproximação $|I(y) - f_i(x)|^2$ na contabilização total da energia local $E_{local}(x)$ deve ser sempre maior nas vizinhanças de x . O cumprimento desta última exigência é assegurado pelas seguintes propriedades, $G(u) > G(v)$, se $|v| > |u|$ e

$$\lim_{u \rightarrow \infty} G(u) = 0, \quad (4.4)$$

inerentes à função gaussiana de média nula.

Outra propriedade importante do núcleo gaussiano é a simetria, definida por $G(u) = G(-u)$, pois garante que *pixels* equidistantes ao ponto localizado pelo centro do núcleo possuam igual peso em relação ao cálculo da energia neste ponto. A minimização dessa energia compõe o critério de otimização do modelo.

4.2 Formulação *Level-Set*

Conforme exposto, o contorno ϕ no modelo *level-set* é a curva de nível da superfície ψ no nível 0. Desse modo, utilizando-se a função degrau suavizada $H(u) = \frac{1}{2}(1 + \frac{2}{\pi} \arctan \frac{u}{\epsilon})$, a equação 4.2 pode ser reescrita em termos de ψ como (LI et al., 2008)

$$E(x) = \sum_{i=1}^2 \lambda_i \int M_i[\psi(y)] G_\sigma(x - y) |I(y) - f_i(x)|^2 dy, \quad (4.5)$$

em que

$$M_1 = H(\psi), \quad (4.6)$$

e

$$M_2 = 1 - H(\psi). \quad (4.7)$$

Os termos M_1 e M_2 representam as regiões acima e abaixo do nível 0 de ψ , evitando uma manipulação adicional dos limites de integração relacionados ao contorno, e o parâmetro ϵ ajusta o grau de suavidade da função degrau utilizada. O delta de Dirac suavizado, derivada da função H em relação a u também possui utilidade no modelo e é dado por (LI et al., 2008)

$$\delta(u) = \frac{\epsilon}{\pi(\epsilon^2 + u^2)} \quad (4.8)$$

A partir da abordagem descrita, a melhor escolha para as aproximações f_1 e f_2 é aquela que anula os erros quadráticos ponderados pelo núcleo gaussiano, ou seja, que satisfaz a equação de Euler-Lagrange (LI et al., 2008)

$$\lambda_i \int M_i[\psi(y)] G_\sigma(x - y) (I(y) - f_i(x)) dy = 0, \quad i = 1, 2. \quad (4.9)$$

Isolando os termos $f_i(x)$, obtém-se

$$f_i(x) = \frac{G_\sigma(x) * \{M_i[\psi(x)]I(x)\}}{G_\sigma(x) * M_i[\phi(x)]}. \quad (4.10)$$

As quatro convoluções (duas para f_1 e duas para f_2) a serem calculadas a cada iteração do contorno representam um grande custo computacional para o método. No entanto, expressando-se f_1 e f_2 isoladamente, é possível perceber uma repetição das convoluções $G_\sigma(x) * \{H[\phi(x)]I(x)\}$ e $G_\sigma(x) * H[\phi(x)]$, a saber

$$f_1(x) = \frac{G_\sigma(x) * \{H[\psi(x)]I(x)\}}{G_\sigma(x) * H[\psi(x)]} \quad (4.11)$$

e

$$f_2(x) = \frac{G_\sigma(x) * \mathbf{UM} - G_\sigma(x) * \{H[\psi(x)]I(x)\}}{G_\sigma(x) * \mathbf{UM} - G_\sigma(x) * H[\psi(x)]}, \quad (4.12)$$

em que \mathbf{UM} é uma matriz de mesmas dimensões de I cujos elementos são todos iguais a 1. Desta forma, já que $K_\sigma * \mathbf{UM}$ independe de ψ e só precisa ser calculado uma vez, apenas duas convoluções são calculadas por iteração, diminuindo-se consideravelmente a demanda de processamento pelo algoritmo.

4.3 Regularização e Tamanho do Contorno

Em métodos *level-set*, a superfície ψ pode desenvolver deformidades que comprometam os cálculos durante a evolução do contorno (LI et al., 2005). Para solucionar esse problema, o modelo explorado no Capítulo 3, por exemplo, utiliza um método de aproximação numérica que deve obedecer a uma certa condição de estabilidade.

Todavia, é comum, ao invés disso, inicializar-se ψ como uma função d , representando a menor distância sinalizada ao contorno. Tal função deve diferir da distância euclidiana por possuir sinal negativo dentro do contorno e positivo fora dele, sendo seu módulo sempre igual à distância euclidiana. Essa diferença confere à função d a propriedade de ser suave em todo o espaço, possuindo derivadas definidas inclusive nos pontos pertencentes ao contorno (OSHER; FEDKIW, 2003).

Além dessa propriedade desejável, é possível concluir, através da aplicação do operador gradiente sobre o campo escalar d , que $|\nabla d| = 1$ para todo o domínio x , sendo as curvas de nível de d sempre equidistantes se a distância entre os níveis for sempre a mesma.

A despeito das propriedades interessantes inerentes à função de menor distância sinalizada, ψ tende a se distanciar de d com a evolução temporal. Desse modo existe a necessidade de que a função ψ seja inicializada com valores próximos de d repetidamente. Do ponto de vista prático, a repetição do processo de inicialização pode ser complexo e possui grande custo computacional. Mais que isso, não há consenso a respeito de quando e como inicializar novamente ψ como uma função distância sinalizada (LI et al., 2005).

No sentido de manter a regularidade do contorno, sem que haja necessidade de novas inicializações, é introduzido um termo de regularização do método *level-set* que penaliza as regiões de ψ que se distanciam da função d . O termo proposto é a integral (LI et al., 2005)

$$P(x) = \mu \int \frac{1}{2} (|\nabla \psi(x)| - 1)^2 dx. \quad (4.13)$$

Como d obedece à propriedade $|\nabla d| = 1$, a penalização imposta pelo termo de regularização torna-se alta quando $|\nabla \psi|$ se distancia de 1, ou seja, quando ψ se distancia de d .

Além do termo de regularização, a maioria dos contornos ativos geométricos utiliza um termo que suaviza o contorno C penalizando seu tamanho $|C|$. Então, um outro termo $T = \nu |C|$ é somado à energia funcional. Reescrevendo T em termos de ψ através do uso da função degrau suavizada tem-se (LI et al., 2008)

$$T(x) = \nu \int |\nabla H[\psi(x)]| dx. \quad (4.14)$$

4.4 Equação do Movimento

Finalmente, juntando todos os termos em um só funcional de energia, tem-se que:

$$E_{total} = E + P + T. \quad (4.15)$$

Para minimizar este funcional de energia é utilizado o método do gradiente descendente, que guia a solução a um ponto ótimo com passos no sentido contrário ao crescimento do gradiente de E_{total} , assim (LI et al., 2008)

$$\begin{aligned} \frac{\partial \psi}{\partial t} = & \delta(\psi)(\lambda_2 e_2 - \lambda_1 e_1) + \nu \delta(\psi) \operatorname{div}\left(\frac{\nabla \psi}{|\nabla \psi|}\right) + \\ & \mu[\nabla^2 \psi - \operatorname{div}\left(\frac{\nabla \psi}{|\nabla \psi|}\right)], \end{aligned} \quad (4.16)$$

em que

$$e_i(x) = \int G_\sigma(x - y) |I(y) - f(x)_i|^2 dy, \quad i = 1, 2. \quad (4.17)$$

Substituindo-se a equação 4.17 no termo $\lambda_1 e_1 - \lambda_2 e_2$ da equação 4.16 e utilizando-se o fato de que a integral do núcleo gaussiano ao longo de todo o domínio é unitária, é possível evitar o cálculo das integrais presentes na equação 4.17 escrevendo-se $\lambda_1 e_1 - \lambda_2 e_2$ através de convoluções como

$$I^2(\lambda_1 + \lambda_2) + G_\sigma * 2I(\lambda_2 f_2 - \lambda_1 f_1) + G_\sigma * (\lambda_1 f_1^2 - \lambda_2 f_2^2). \quad (4.18)$$

Assim, inicializando-se ψ como um prisma conforme indicado na seção 3.3 e utilizando-se este valor inicial de ψ na equação do movimento 4.16, pode-se realizar a segmentação de imagens por meio do método *level-set* orientado por regiões.

Apresentadas, ambas as formulações *level-set*, classificadas como métodos de contornos ativos geométricos, discorre-se, a partir de então, a respeito do método dos contornos ativos algébricos e sobre contornos ativos paramétricos em geral.

Capítulo 5

Método dos Contornos Ativos Algébricos

Os contornos ativos tradicionais são formalmente definidos como curvas paramétricas fechadas $c(i) = [x(i), y(i)]$, em que $c(i)$ é o contorno formado pelo conjunto de pontos de coordenadas cartesianas $x(i)$ e $y(i)$, chamados de nós, e i é o parâmetro segundo o qual estas coordenadas variam, daí a terminologia *snake* paramétrico encontrada na literatura. Este contorno sofre sucessivas iterações, de maneira tal que, sua função de energia é minimizada conforme seus pontos se aproximam das bordas da região interesse. A função de energia dos *snakes* tradicionais é dada por (KASS; WITKIN; TERZOPOULOS, 1988)

$$E = \int E_{int} + \int E_{ext}, \quad (5.1)$$

em que E_{int} é a energia interna, que depende somente da geometria do contorno, e E_{ext} é a energia externa, que independe do contorno, sendo função apenas da imagem.

A otimização do método é realizada localmente através da busca pelo ponto de mínima energia dentro de uma janela com centro em um dos nós do contorno. Então, conforme ilustra a Figura 5.1, cada nó migra para o ponto de mínima energia encontrado em sua vizinhança, sendo suas coordenadas atualizadas, e o contorno movimentado.

5.1 Formulação do Método dos Contornos Ativos Algébricos

Um inconveniente associado a abordagem dos contornos ativos paramétricos tradicionais é a limitação do movimento do contorno ao tamanho da janela de busca, privando




Figura 5.1: janela de busca pelo *pixel* de menor energia (em vermelho) no método dos contornos ativos tradicionais.

o mesmo de movimentar-se para além de alguns *pixels* por iteração. Todavia, conforme o tamanho da janela aumenta, as operações de busca e comparação tornam-se por demais onerosas para o desempenho do método, sendo cada iteração responsável por um acréscimo no tempo de processamento.

Uma maneira de superar a limitação imposta pela necessidade de realizar buscas e comparações é descrever completamente o movimento do contorno através de uma equação algébrica. Dessa maneira, a exemplo de como ocorre nos métodos *level-set*, elimina-se a dependência de uma janela de busca por parte do método, associando-se ao contorno uma equação do movimento.

Assim, seja uma curva parametrizada $c(i)$ inicialmente representada pelo vetor de coordenadas $[x_0(i), y_0(i)]$ normalizada entre -1 e 1. Assim, a simples multiplicação das equações paramétricas por um fator constante, ou seja, o produto do vetor $c(i) = [x_0(i), y_0(i)]$ por um escalar, tem como efeito o escalonamento desta curva. Em outras palavras, a depender do fator, a curva aumenta ou diminui, mantendo o gráfico original e modificando apenas a escala dos eixos ortogonais. No presente trabalho, esta propriedade é utilizada para movimentar um contorno. A normalização é realizada com o objetivo de escalonar a curva em relação a seu ponto central sem que haja translação.

Deste modo, seja $c_0(i) = [x_0(i), y_0(i)]$ o contorno inicial, a equação do movimento do contorno é dada em notação vetorial por

$$(x, y) = (x_0, y_0) + sa(x_0, y_0)\Delta t, \tag{5.2}$$

em que Δt é o intervalo de tempo decorrido, a é a taxa de aumento da escala e s o sinal que indica o sentido do movimento, sendo negativo para contornos que se contraem e positivo para contornos que se expandem.

A adição de termos de concavidade ao fator sa possui o efeito de suavizar o gráfico das equações paramétricas $x(i)$ e $y(i)$, o que se manifesta na curva $c(i)$ como o achatamento de regiões pontiagudas, tornando o contorno mais arredondado. Então, com o acréscimo

dos termos de concavidade, a equação do movimento passa a ser dada por

$$(x, y) = (x_0, y_0) + sa[(K_x + 1)x_0, (K_y + 1)y_0]\Delta t, \quad (5.3)$$

sendo

$$\begin{aligned} K_x(j) &= \frac{D_x(l, j) - D_x(j, h)}{dx} \text{ e} \\ K_y(j) &= \frac{D_y(l, j) - D_y(j, h)}{dy}. \end{aligned} \quad (5.4)$$

A derivada $D_u(p_1, p_2)$ de uma equação paramétrica genérica u em relação ao parâmetro i é calculada utilizando os pontos $i = p_1$ e $i = p_2$, conforme ilustra a Figura 5.2, da seguinte forma:

$$D_u(p_1, p_2) = \frac{u(p_1) - u(p_2)}{di}. \quad (5.5)$$




Figura 5.2: cálculo do termo de curvatura com 5 pontos.

O vetor que representa o contorno é tratado como um *buffer* circular para que as derivadas possam ser calculadas em quaisquer de seus pontos.

Então, a fim de utilizar o contorno descrito para segmentação de imagens, é necessária a inserção no modelo de um mecanismo que faça o mesmo parar ao alcançar as bordas dos objetos. Desse modo, para que cada ponto do contorno cesse gradualmente seu movimento, ao se aproximar das bordas, utiliza-se um vetor de velocidades escalares $v(i)$, ou seja, um vetor que regula a velocidade de cada ponto do contorno à mesma proporção para ambas as coordenadas. O resultado da incorporação de $v(i)$ à equação do movimento é dado por

$$(x, y) = (x_0, y_0) + v[(K_x + sa)x_0, (K_y + sa)y_0]\Delta t. \quad (5.6)$$

É comum que haja modificações no cálculo do vetor velocidade de imagem para imagem, por este exigir conhecimento *a priori* acerca das mesmas. Um dos modos de realizar

este cálculo é por meio de um mapa de contornos. Então, sejam X e Y as colunas e linhas de uma imagem digital $I(X, Y)$, o mapa de contornos $M(X, Y)$ desta imagem é uma matriz de mesmas dimensões de I que realça suas regiões de interesse.

Para montar um vetor velocidade $v(i)$, a partir do mapa de contornos $M(X, Y)$, devem ser utilizados pontos de um outro contorno $C(i) = [X(i), Y(i)]$ definido sobre o mesmo domínio da imagem. Então, $v(i)$ é dado como função de $M(X, Y)$ por

$$v(i) = f(M(X(i), Y(i))) \quad (5.7)$$

O vetor $C_0(i) = [X_0(i), Y_0(i)]$ é definido sobre a imagem na inicialização do algoritmo, de modo que $c_0(i) = [x_0(i), y_0(i)]$ é um mapeamento dos pontos extremos (mais à direita, mais à esquerda, mais abaixo e mais acima) da curva C_0 para valores de x e y iguais a -1 e 1. Assim, para obter o vetor $C(i)$ a cada iteração, deve ser realizado um mapeamento inverso dos limites do domínio $x \times y$ para as dimensões da imagem, ou seja, os valores máximos que X e Y podem assumir. Em outras palavras, os contornos c e C se movem conjuntamente em diferentes domínios.

5.1.1 Superposição de Gradientes

Conforme descrito na seção 2.4, o gradiente é uma medida capaz de detectar bordas em uma imagem. Todavia, uma das limitações de métodos que utilizam medidas de descontinuidade para detecção de bordas é a dimensão reduzida da área de influência das mesmas. Em muitos casos, o gradiente da imagem influencia apenas áreas muito próximas das bordas, o que, a depender das condições iniciais, pode dificultar sua detecção por parte do contorno ativo. Uma possível solução para esta dificuldade é filtrar o gradiente com uma janela gaussiana de tamanho e desvio-padrão ajustáveis. O desvio-padrão e as dimensões da janela são responsáveis por regular o tamanho da área que passa a ser influenciada pelo gradiente na vizinhança de cada *pixel*. Essa medida, todavia, borra o gradiente, comprometendo a localização precisa das bordas do objeto. Logo, a simples variação dos parâmetros da janela gaussiana conduz irremediavelmente a um dos dois problemas, ou à imprecisão na localização das bordas, ou à restrição da área de alcance das mesmas pelo contorno.

A solução proposta é utilizar como mapa de contornos uma superposição de dois gradientes, ao invés de apenas um. Essa superposição deve ser ponderada por constantes que indiquem a contribuição de cada mapa de contorno no mapa resultante. O primeiro mapa é calculado como função de um gradiente puro e o segundo como função de um

gradiente filtrado por uma janela gaussiana de tamanho N_{MAPA} , desvio-padrão σ_{MAPA} e média nula.

Uma das maneiras de realizar o cálculo do mapa de contornos a partir da imagem é através da equação 5.8, sendo utilizada por este modelo na segmentação das imagens extraídas de exames de ecocardiograma. Nesse contexto, sendo α e β constantes de ponderação, X e Y as colunas e linhas da imagem I , e $G_{n_{MAPA} \times n_{MAPA}}(\sigma_{MAPA})$ uma janela gaussiana $n_{MAPA} \times n_{MAPA}$ de média nula e desvio-padrão σ_{MAPA} , um mapa de contornos é definido por (MESQUITA, 2009)

$$M(X, Y) = \alpha \nabla I(X, Y) + \beta [\nabla I(X, Y) * G_{n_{MAPA} \times n_{MAPA}}(\sigma_{MAPA})]. \quad (5.8)$$

A primeira parcela do mapa de contornos é responsável por detectar a localização precisa das bordas dos objetos, enquanto a segunda aumenta a área de influência das mesmas.

Finalmente, o vetor velocidade $v = f(M)$ utilizado na segmentação destas imagens é dado por (MALLADI; SETIAN; VEMURI, 1995)

$$v(i) = \frac{1}{[1 + M(X(i), Y(i))]^n}, \quad (5.9)$$

em que n é a ordem da função não linear que regula o nível de influência da imagem sobre a velocidade do contorno. Assim, quanto maior o valor de n , mais rapidamente a velocidade do contorno decai ao alcançar regiões de alto gradiente.

5.2 *PSnakes*

O *PSnakes* é uma modalidade de contornos ativos cujos pontos são representados através de um sistema de coordenadas polares. O fato de o eixo deste sistema de coordenadas se localizar no ponto de divergência de feixes ultrassônicos em uma imagem de ecocardiograma torna o método em questão particularmente útil para segmentação do VE nestas imagens (ALEXANDRIA, 2011).

A definição matemática do *PSnakes* é dada por (ALEXANDRIA, 2011)

$$\begin{cases} [0, 1] \rightarrow \mathfrak{R}^2 \\ c(s) \rightarrow [r_1(s), \theta(s)]; [r_2(s), \theta(s)], \end{cases} \quad (5.10)$$

em que $[r_1(s), \theta(s)]$ e $[r_2(s), \theta(s)]$ é o conjunto de pontos que formam o contorno c , chamados de nós. As variáveis r_1 e r_2 são as respectivas coordenadas radiais de cada um dos dois nós localizados sobre uma mesma reta oriunda da origem do sistema de coordenadas,

denominados nós gêmeos. Assim, os nós gêmeos localizados nos raios $r_1(s)$ e $r_2(s)$ possuem a mesma coordenada angular θ . Os valores de $r_1(s)$ e $r_2(s)$ são limitados ao intervalo $[0, r_{max}]$, em que r_{max} é a distância máxima alcançada pelo feixe ultrassônico. Do mesmo modo, os valores de θ estão limitados ao intervalo $[\theta_{min}, \theta_{max}]$, que corresponde ao setor de varredura do feixe. O arranjo geométrico do método *PSnakes* é ilustrado na Figura 5.3 (ALEXANDRIA, 2011).




Figura 5.3: sistema de coordenadas e parametrização do contorno no método *PSnakes* (ALEXANDRIA, 2011).

Similarmente aos contornos ativos paramétricos tradicionais, a otimização do método *PSnakes* é realizada através da minimização de uma energia total. Esta minimização é realizada localmente através do deslocamento dos nós do contorno para pontos de mínima energia dentro de uma janela de busca. Todavia, no caso do método *PSnakes*, a janela de busca é unidimensional, representando *pixels* de mesma coordenada angular. Esta característica demanda menor esforço computacional por parte do *PSnakes* em relação aos MCA paramétricos tradicionais, que utilizam sistema de coordenadas cartesianas e janela de busca bidimensional.

A energia interna do *PSnakes*, composta por energia de curvatura E^{curv} e energia de continuidade E^{cont} , é dada por:

$$E_{int} = E_{r,\theta}^{curv} + E_{r,\theta}^{cont} \quad (5.11)$$

As energias de curvatura e continuidade são dadas por (ALEXANDRIA, 2011)

$$E_{r,\theta}^{curv} = [(r_\theta - r_{\theta+1}) - (r_{\theta+1} - r_{\theta+2})]^2 \quad (5.12)$$

$$E_{r,\theta}^{cont} = (r_\theta - r_{\theta+1})^2, \quad (5.13)$$

em que r_θ é a coordenada radial de um dado nó ao longo do feixe de ângulo θ . Os valores de $r_{\theta+1}$ e $r_{\theta+2}$ são as coordenadas radiais dos nós subsequentes, cujas coordenadas angulares são dadas por $\theta + 1$ e $\theta + 2$ respectivamente.

Com a finalidade de facilitar a expansão e a contração do contorno ativo, adiciona-se à energia já existente um tipo de energia chamada balão, que acelera o movimento radial do contorno, sendo esta dada por (ALEXANDRIA, 2011):

$$E^b(r, \theta) = \begin{cases} \delta \frac{2r(\theta)}{r_1(\theta) + r_1(\theta)}, & \text{para } r(\theta) \leq \frac{r_1(\theta) + r_2(\theta)}{2}; \\ 1 - \delta \frac{r(\theta)}{r_{\max}}, & \text{para } r(\theta) > \frac{r_1(\theta) + r_1(\theta)}{2}; \end{cases} \quad (5.14)$$

em que $r_1(r)$ e $r_2(r)$ são as coordenadas radiais dos nós gêmeos sobre o feixe de ângulo θ , e δ é uma constante.

Para realizar a segmentação de imagens a energia total deve incorporar um termo que possua dependência com a imagem do objeto de interesse. Nesse sentido, haja vista a característica de apresentar picos em regiões de borda, quando aplicada sobre imagens digitais, a transformada Hilbert pode ser aplicada a sinais biomédicos bidimensionais, como é o caso das imagens de ecocardiograma. A transformada Hilbert de uma imagem digital I é dada pela convolução (ALEXANDRIA, 2011)

$$H\{I(x, y)\} = \frac{1}{\pi t} * I(x, y) \quad (5.15)$$

Então, devido as características de detecção e suavização de borda, a transformada Hilbert H é utilizada para o cálculo de energia externa do *PSnake*. A transformada Hilbert sobre os feixes de ultrassom $H(r_\theta)$ deve ser tomada pelos valores absolutos e normalizada no intervalo $[0, 1]$. Assim, a energia externa é dada por (ALEXANDRIA, 2011):

$$E_{r,\theta}^{ext} = E_{r,\theta}^{hilbert} = 1 - \frac{|H(r_\theta)|}{\max |H(r_\theta)|}. \quad (5.16)$$

Por fim, a energia total a ser minimizada pelo método *PSnakes* é dada por (ALEXANDRIA, 2011):

$$pE_{r,\theta}^{total} = \alpha E_{r,\theta}^{curv} + \beta E_{r,\theta}^{cont} + \delta E_{r,\theta}^b + \gamma E_{r,\theta}^{ext}, \quad (5.17)$$

em que p , α , β , δ e γ são constantes de ponderação.

O método *PSnakes* é utilizado com a finalidade de realizar uma comparação quantitativa o MCA algébrico a outro método presente na literatura, já que conclui-se, no Capítulo 7, ser inviável compará-lo aos métodos *level-set* em imagens de ecocardiograma. Neste trabalho, tal comparação possui propósito exemplificativo, não sendo seus resultados alvos de discussões conclusivas.

Capítulo 6

Resultados em Imagens Sintéticas

6.1 Metodologia dos Testes em Imagens Sintéticas

Com o intuito de testar e avaliar os métodos apresentados para segmentação de propósito geral, estes são aplicados em uma imagem de objeto com concavidade, uma imagem de objeto com borda descontínua, uma imagem com vários objetos, uma imagem com regiões não-homogêneas e uma imagem corrompida por ruído branco (AWGN). O ambiente utilizado foi o MATLAB, versão 2011.

O critério de parada utilizado para a obtenção das imagens resultantes é o fim do movimento da frente, sendo os valores dos parâmetros específicos de cada modelo encontrados heurísticamente. Os valores desses parâmetros utilizados em cada um dos casos são mostrados nas Tabelas 6.1, 6.2 e 6.3. Para alguns cálculos de mapas de contorno e termos de velocidade são utilizadas binarizações por limiar, abordadas na seção 2.3, a fim de auxiliar a localização das regiões de interesse.

Tabela 6.1: Parâmetros do método *level-set* orientado por gradiente aplicado à imagens sintéticas

	Δx	Δy	Δt	s	ϵ	σ	n	Velocidade
com Concavidade	2	2	30	-1	0	3,5	10	$U_{ij}^{(1)}$
com Bordas Descontínuas	2	2	30	1	0	3,5	10	$U_{ij}^{(2)}$
com Vários Objetos	2	2	30	-1	0	3,5	10	$U_{ij}^{(3)}$
com Regiões Não-Homogêneas	2	2	25	-1	0,25	-	-	$U_{ij}^{(4)}$
com Presença de Ruído	2	2	30	-1	0	2	5	$U_{ij}^{(5)}$

Então, seja $G_{n \times n}(\sigma)$ uma janela $n \times n$ gaussiana de média nula e desvio-padrão σ , os termos de velocidade do método *level-set* orientado por gradiente referenciados na última coluna da Tabela 6.1 são dados por:

$$U_{ij}^{(1)} = I_{ij} - \frac{1}{2}I_{ij} * G_{10 \times 10}(3, 5), \quad (6.1)$$

$$U_{ij}^{(2)} = I_{ij} - \frac{1}{2}I_{ij} * G_{10 \times 10}(3, 5), \quad (6.2)$$

$$U_{ij}^{(3)} = 1 - I_{ij}, \quad (6.3)$$

$$U_{ij}^{(4)} = \begin{cases} 1, & \text{se } |\nabla I_{ij} * G_{3 \times 3}(1)| < 0,63, \\ 0, & \text{c.c.,} \end{cases} \quad (6.4)$$

e

$$U_{ij}^{(5)} = \begin{cases} 1, & \text{se } |\nabla I_{ij}| < 0,3, \\ 0, & \text{c.c.} \end{cases} \quad (6.5)$$

Tabela 6.2: Parâmetros do método *level-set* orientado por regiões aplicado a imagens sintéticas

	λ_1	λ_2	dt	μ	ϵ	ν	σ	n
com Concavidade	1	0,8	0,05	1	10	130	20	50
com Bordas Descontínuas	1	0,8	0,05	1	10	130	20	50
com Vários Objetos	1	0,8	0,05	1	10	130	10	20
com Regiões Não-Homogêneas	1	1	0,1	1	1	130	8	30
com Presença de Ruído	1	0,8	0,1	1	1	130	8	30

Tabela 6.3: Parâmetros do método dos contornos ativos algébricos aplicado a imagens sintéticas

	di	Δt	s	a	α	β	v
com Concavidade	10^{-2}	10^{-5}	-1	0,3	-	-	M_1
com Bordas Descontínuas	10^{-2}	10^{-5}	-1	0,3	-	-	M_2
com Vários Objetos	10^{-2}	10^{-5}	-1	0,3	2	1	$f(M_3)$
com Regiões Não-Homogêneas	10^{-2}	10^{-5}	-1	0,3	-	-	M_4
com Presença de Ruído	10^{-2}	10^{-5}	-1	0,3	-	-	M_5

No MCA algébrico, os vetores velocidade são calculados a partir dos mapas de contorno referenciados na última coluna da Tabela 6.3, dados por

$$M_1 = M_2 = I(X, Y), \quad (6.6)$$

$$M_3(X, Y) = \alpha \nabla I(X, Y) + \beta [\nabla I(X, Y) * G_{100 \times 100}(30)], \quad (6.7)$$

sendo f dado pela equação 5.9,

$$M_2(X, Y) = \begin{cases} 1, & \text{se } |\nabla I(X, Y) * G_{3 \times 3}(1)| < 0,63, \\ 0, & \text{c.c.} \end{cases} \quad (6.8)$$

e

$$M_3(X, Y) = \begin{cases} 1, & \text{se } |\nabla I(X, Y)| < 0,3 \\ 0, & \text{c.c.} \end{cases} \quad (6.9)$$

São mostrados os resultados na seguinte sequência: em imagens com concavidade, com bordas descontínuas, com vários objetos, com regiões não-homogêneas e com presença de ruído. Os contornos finais obtidos pelo método *level-set* orientado por gradiente são mostrados em vermelho, pelo *level-set* orientado por regiões em verde e, pelo método dos contornos ativos algébricos, em azul claro.

Todas as explicações para os comportamentos observados nos resultados são dadas na seção 6.7.

6.2 Resultados Para Objeto com Concavidade

Os contornos gerados pelo método *level-set* orientado por gradiente após inicialização próxima aos pontos extremos da imagem, após 14 iterações e após 30 iterações são mostrados nas Figuras 6.1 (a), 6.1 (b) e 6.1 (c). Para o caso de uma curva de inicialização dentro do objeto, a evolução da frente gerada pelo método *level-set* é mostrada nas Figuras 6.1 (d), 6.1 (e) e 6.1 (f).

O contorno gerado pelo método *level-set* orientado por regiões após 50 iterações é mostrado nas Figuras 6.2 (b) e 6.2 (d), sendo a inicialização próxima aos extremos da imagem no primeiro caso, e dentro do objeto no último. Observando-se as Figuras é possível perceber que o método *level-set* orientado por regiões apresenta falhas na segmentação, pois o contorno permanece quase imóvel em iterações sucessivas.

O resultado obtido pela aplicação do MCA algébrico em uma imagem cujo objeto em cena apresenta concavidade é mostrado nas Figuras 6.3 (a) e 6.3 (b), sendo a inicialização do contorno exterior ao objeto. Para o caso de uma inicialização no interior do objeto, o comportamento do contorno ativo algébrico é mostrado nas Figuras 6.3 (c) e 6.3 (d). Pela observação das Figuras 6.3 (b) e 6.3 (d), identifica-se no MCA algébrico uma limitação para acomodar o contorno às regiões côncavas dos objetos.

6.3 Resultados Para Objeto com Borda Descontínua

O contorno gerado pelo método *level-set* orientado por gradiente após inicialização exterior ao objeto, 32 iterações, 50 iterações e 75 iterações é mostrado nas Figuras 6.4 (a), 6.4 (b), 6.4 (c) e 6.4 (d) respectivamente.

Similarmente aos resultados mostrados na seção 6.2, o contorno gerado pelo método *level-set* orientado por regiões permaneceu inerte após ser inicializado em regiões sem variação no tom de cinza dos *pixels*, por isto este resultado não é mostrado.

Um dos resultados obtidos pela aplicação do MCA algébrico em uma imagem cujo objeto em cena apresenta bordas descontínuas é mostrado nas Figuras 6.5 (a) e 6.5 (b). Observa-se que o MCA algébrico testado apresenta limitação na segmentação de um objeto com bordas descontínuas. Apesar de apenas a inicialização dentro do objeto ter sido mostrada, esta conclusão se estende ao cenário no qual a inicialização é definida fora do objeto, já que este recai no caso investigado na seção 6.2.

6.4 Resultados Para Vários Objetos

Os contornos gerados pelo método *level-set* orientado por gradiente após inicialização próxima aos pontos extremos da imagem, 24 iterações e 30 iterações são mostrados nas Figuras 6.6 (a), 6.6 (b) e 6.6 (c).

A exemplo das Seções anteriores, os resultados gerados pelo método *level-set* orientado por regiões não são mostrados, já que o contorno permanece inalterado devido à presença de grandes regiões de tom de cinza constante.

Nesta imagem, é aplicado o MCA algébrico a partir de uma inicialização fora da região de interesse. A evolução do método é mostrada nas Figuras 6.7 (a) e 6.7 (b). É possível perceber, pela observação dessas Figuras, que, apesar de o MCA algébrico ser dotado de sensibilidade às bordas, o mesmo não consegue segmentar os vários objetos presentes na imagem devido à sua limitação de possuir contorno único.

6.5 Resultados Para Regiões Não-Homogêneas

A aplicação dos métodos apresentados na imagem não-homogênea se destina a testar sua habilidade de segmentar imagens cujo tom de cinza não seja um atributo capaz de discriminar integralmente seus objetos. Esta incapacidade é exemplificada através de uma

binarização por limiar mostrada na Figura 6.8 (a). Os contornos obtidos pelo método *level-set* orientado por gradiente após inicialização próxima aos pontos extremos da imagem, 25 e 40 iterações são mostrados na Figuras 6.8 (b), 6.8 (c) e 6.8 (d), respectivamente.

A evolução do contorno gerado pelo método *level-set* orientado por regiões é mostrada na Figura 6.9. Como a intensidade dos *pixels* é a principal propriedade da imagem utilizada por este método, o mesmo tende a confundir objeto com fundo em regiões onde seus níveis de cinza são similares, a exemplo da Figura 6.8 (a).

O resultado do método dos contornos ativos algébricos na imagem não-homogênea é mostrado na Figura 6.10. Novamente, devido a sua incapacidade de dividir-se, o contorno ativo algébrico falha em segmentar os vários objetos presentes na imagem, não obstante detectar parte de suas bordas.

6.6 Resultados em Imagens Ruidosas

Para submeter os métodos apresentados aos testes de tolerância a ruído, uma imagem é corrompida com vários níveis de ruído branco gaussiano aditivo (AWGN) de média nula. A relação sinal-ruído (SNR) é medida, em decibéis, como a relação entre a potência média da imagem e a potência média do ruído. Então, seja $E[.]$ definido como o operador esperança matemática de ”.”, o valor médio da potência da imagem é dado pela média quadrática $E[I^2] = \mu_I^2 + \sigma_I^2$ da variável aleatória I correspondente a intensidade da imagem, em que μ_I e σ_I^2 são sua média e variância respectivamente. Da mesma maneira, a potência média do ruído AWGN é dada pela sua própria variância, já que sua média é nula.

Os valores de SNR são escolhidos de modo que a variância do ruído assuma valores iguais a 1×10^{-3} , 5×10^{-3} , 9×10^{-3} e 5×10^{-2} , que correspondem a valores de SNR iguais a 39,52 dB, 32,54 dB, 31,07 e 22,55 dB respectivamente.

Desse modo, a Figura 6.11 mostra a segmentação resultante após 100 iterações da aplicação do método *level-set* orientado por gradiente para três níveis de ruído AWGN. Por meio da observação desta Figura, nota-se o aparecimento de contornos inadequados conforme diminui a relação sinal-ruído, o que evidencia a sensibilidade a ruído do método *level-set* orientado por gradiente.

A segmentação resultante da aplicação do método *level-set* orientado por regiões para quatro níveis de ruído AWGN após 30 iterações é mostrada na Figura 6.12.

O método dos contornos ativos algébricos se mostra o mais sensível aos efeitos do ruído AWGN nos experimentos. A Figura 6.13 mostra os resultados de sua aplicação após 50

iterações.

6.7 Conclusão do Capítulo

A respeito do método *level-set* orientado por gradiente, conclui-se, a partir dos resultados obtidos, que estes apresentam menor sensibilidade a variações na inicialização em relação ao método dos contornos ativos algébricos, como se observa comparando-se as Figuras 6.1 (c) e 6.1 (f) com as Figuras 6.3 (b), 6.3 (d).

A maior dependência à inicialização dos contornos ativos algébricos observada através dessa comparação se deve à restrição das operações algébricas que movem o contorno a seus próprios pontos de controle, ao passo que, nos métodos *level-set* estudados, tais operações são realizadas em todos os pontos da imagem, sendo os contornos definidos simplesmente como parte da topologia resultante dessas operações.

A ligação do movimento do MCA algébrico a seus nós, é, também, o fator que conduz este método a não segmentar satisfatoriamente objetos com concavidade. Isto porque a área de influência das bordas em regiões côncavas, por vezes, não alcança pontos próximos ao contorno, fazendo com que o mesmo ignore tais regiões. Os métodos *level-set*, por sua vez, alcançam regiões côncavas naturalmente. Dessa forma, a falha do método *level-set* orientado por regiões na segmentação do objeto com concavidade mostrada na Figura 6.2 não se deve a uma deficiência em alcançar concavidades, mas em outro aspecto específico.

Observa-se que, nos testes realizados em imagens com grandes regiões sem variação no tom de cinza, o método *level-set* orientado por regiões não segmenta a imagem adequadamente. Este fato se explica pela ausência, em sua formulação, de um mecanismo eficaz que faça com que a frente consiga se movimentar, independentemente do tipo imagem sobre a qual esta se propaga. Assim este método necessita de variações nos tons de cinza da imagem para funcionar adequadamente. Por exemplo, o contorno do método *level-set* orientado por regiões não consegue se mover através de uma imagem que seja toda da mesma cor, diferentemente do orientado por gradiente e do MCA algébrico.

Devido a esta dependência às variações locais de intensidade dos *pixels*, o método *level-set* orientado por regiões apresenta os melhores resultados nos testes de tolerância a ruído, como se verifica na comparação das Figuras 6.11 (b), 6.12 (b) e 6.13 (b), em que as imagens são corrompidas com o mesmo nível de ruído. Para realizar a detecção de bordas, os outros dois métodos testados utilizam diferenças finitas, que amplificam a informação presente nas frequências onde há mais ruído, potencializando seus efeitos e resultando em

uma maior dificuldade de segmentação.

Finalmente, a partir dos experimentos cujos resultados são ilustrados nas Figuras 6.6 (c), 6.8 (d) e 6.9 (c), observa-se que ambos os métodos *level-set* confirmam a hipótese teoricamente prevista de que o contorno é capaz de segmentar vários objetos em uma só imagem, o que não ocorre com o contorno ativo algébrico. Isto se deve à formulação Euleriana do método *level-set*, em que o contorno é definido implicitamente sem que haja a necessidade de parametrização.

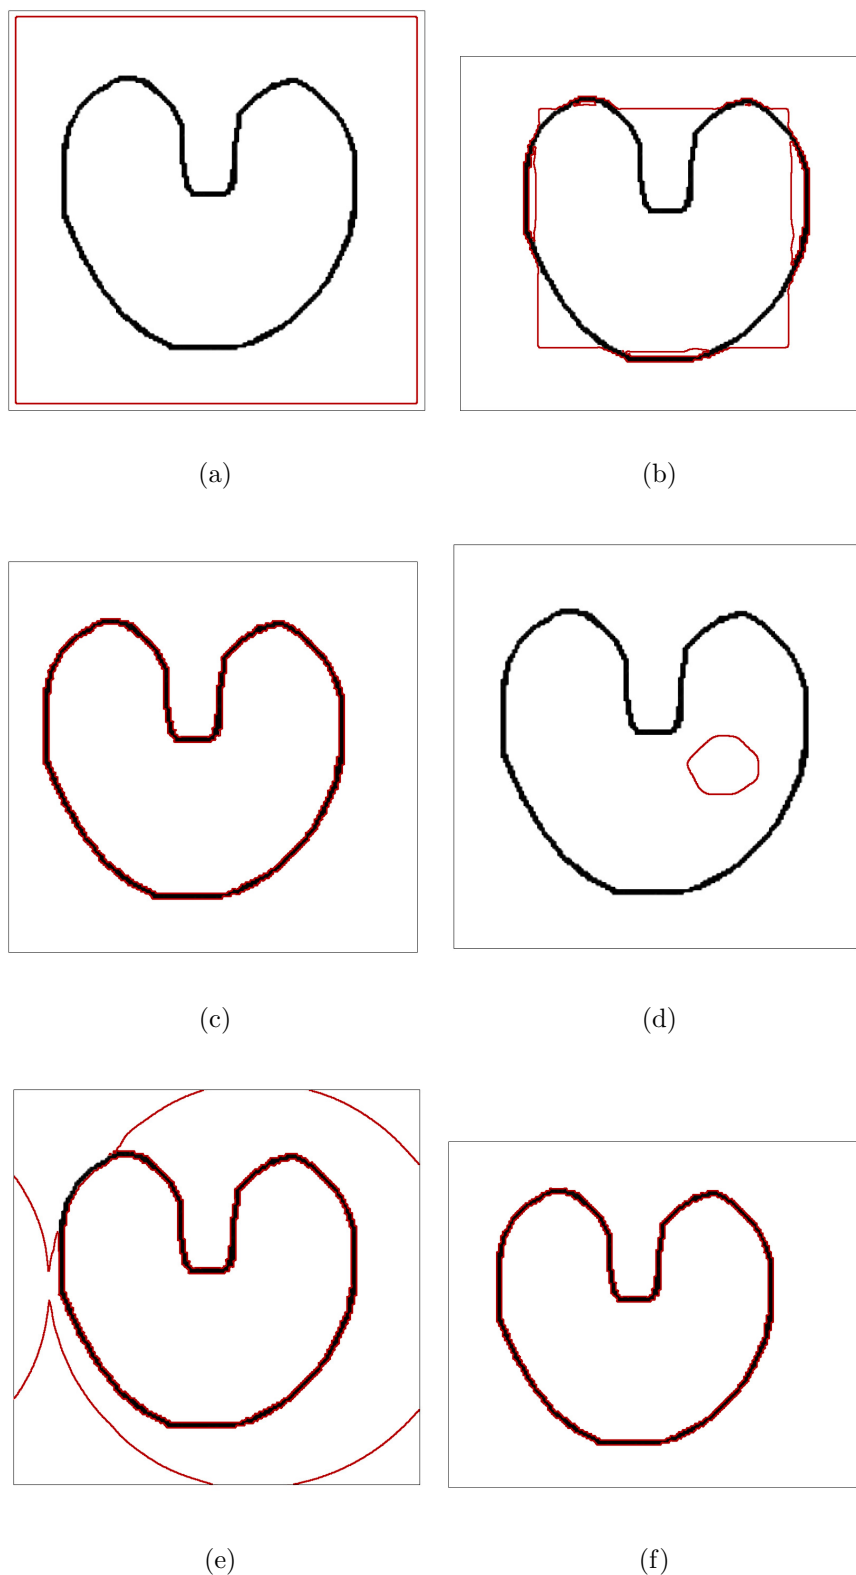


Figura 6.1: resultados obtidos pelo método *level-set* orientado por gradiente em imagem com concavidades (a) com inicialização próxima aos pontos extremos da imagem, (b) 14 iterações e (c) 30 iterações; (d) com inicialização dentro do objeto, (e) 42 iterações e (f) 60 iterações.

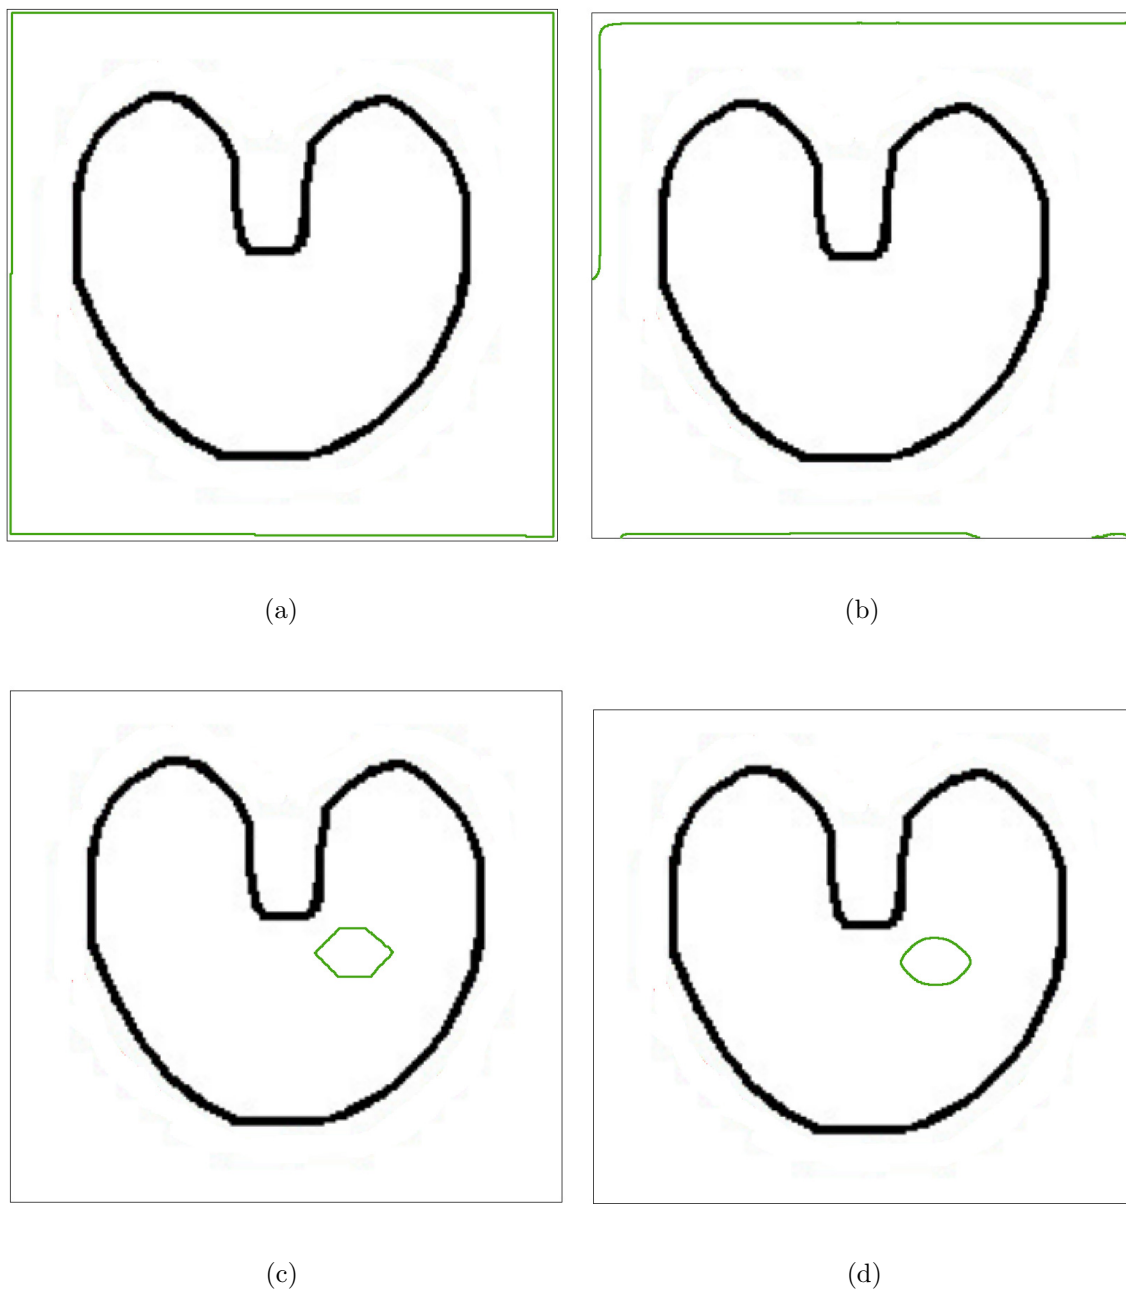


Figura 6.2: contorno obtido pelo método *level-set* orientado por regiões em imagem com concavidades (a) com inicialização próxima aos pontos extremos da imagem e (b) após 50 iterações; (c) com inicialização dentro do objeto e (d) após 50 iterações.




Figura 6.3: resultados obtidos pelo MCA algébrico em imagem com concavidades (a) com inicialização ao redor do objeto e (b) após 25 iterações; (c) com inicialização dentro do objeto e (d) após 60 iterações

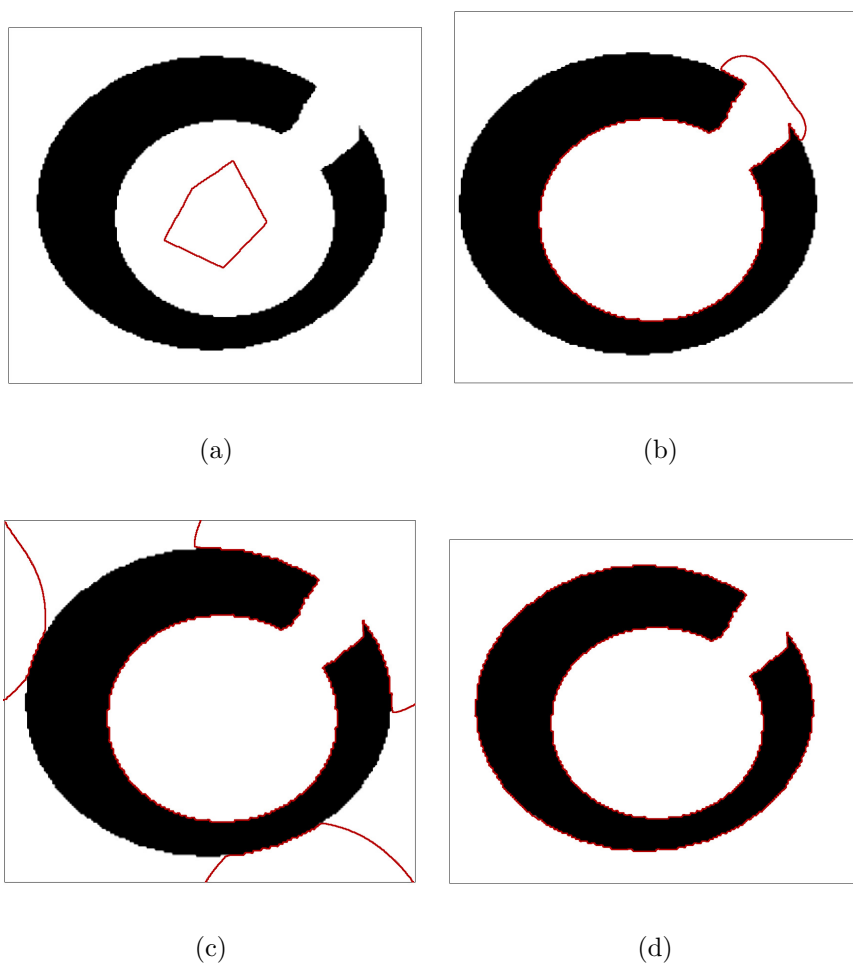


Figura 6.4: resultado obtido pelo método *level-set* orientado por gradiente em imagem com bordas descontínuas (a) após inicialização dentro do objeto, (b) 32 iterações, (c) 50 iterações e (d) 75 iterações.

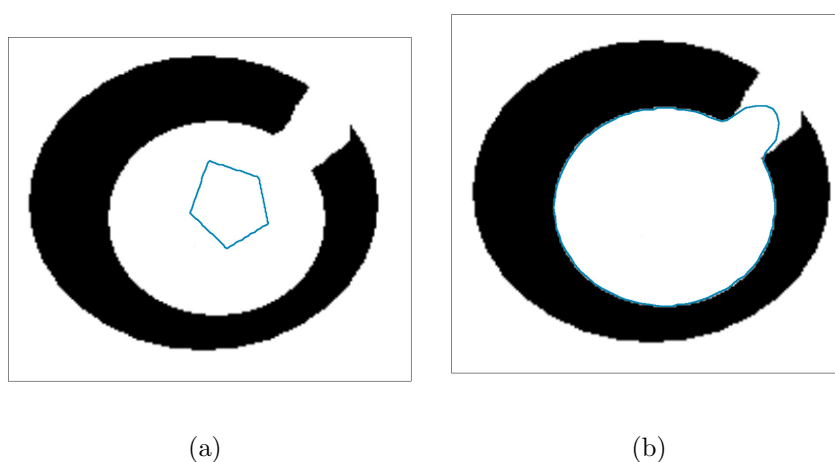





Figura 6.5: resultado obtido pelo MCA algébrico em imagem com bordas descontínuas (a) após inicialização dentro do objeto com bordas descontínuas e (b) após 60 iterações.



(a)




(b)




(c)

Figura 6.6: resultado obtido pelo método *level-set* orientado por gradiente para vários objetos (a) após inicialização próxima aos pontos extremos da imagem, (b) 24 iterações e (c) 30 iterações.



(a)



(b)

Figura 6.7: resultado obtido pelo MCA algébrico para vários objetos (a) após inicialização fora da região de interesse e (b) após 30 iterações.







Figura 6.8: (a) exemplo de imagem não-homogênea binarizada por limiar; resultado obtido pelo método *level-set* orientado por gradiente para regiões não-homogêneas (b) após inicialização próxima aos pontos extremos da imagem, (c) 25 iterações e (d) 40 iterações.



(a)




(b)




(c)


Figura 6.9: resultado obtido pelo método *level-set* orientado por regiões para regiões não-homogêneas (a) após inicialização próxima aos pontos extremos da imagem, (b) 15 iterações e (c) 50 iterações.



(a)



(b)



(c)

Figura 6.10: resultado obtido pelo MCA algébrico para regiões não-homogêneas (a) após inicialização próxima aos pontos extremos da imagem, (b) 15 iterações e (c) 30 iterações.




Figura 6.11: resultados obtidos pelo método *level-set* orientado por gradiente aplicado a imagem com SNR de (a) 39,52 dB, (b) 32,54 dB e (c) 31,07 dB.




Figura 6.12: resultados obtidos pelo método *level-set* orientado por regiões aplicado a imagem com SNR de (a) 39,52 dB, (b) 32,54 dB, (c) 31,07 dB e (d) 22,55 dB.




Figura 6.13: resultados obtidos pelo MCA algébrico aplicado a imagem com SNR de (a) 39,52 dB e (b) 32,54 dB.

Capítulo 7

Resultados em Imagens de Ecocardiografia

7.1 Metodologia dos Testes em Imagens de Ecocardiografia

Após apresentados e testados em imagens sintéticas, ambos os métodos *level-set* e o MCA algébrico são aplicados sobre imagens extraídas de exames de ecocardiografia com o propósito de segmentar o ventrículo esquerdo. O critério de parada utilizado é o fim do movimento do contorno em todos os casos. Os resultados mostrados em decorrência da aplicação destes métodos são obtidos utilizando-se os parâmetros constantes na Tabela 7.1, encontrados heurísticamente. O ambiente foi o mesmo utilizado nos testes em imagens sintéticas.

Tabela 7.1: Parâmetros utilizados para imagens de ecocardiografia

Método Level-Set	Δx	Δy	Δt	s	ϵ	σ	n	Velocidade
Orientado por Gradiente	2	2	30	-1	0	10	40	U_{ij}^{eco}
Método Level-Set	λ_1	λ_2	dt	μ	ϵ	ν	σ	n
Orientado por Gradiente	1	1	0,1	1	0,5	130	60	120
MCA	di	Δt	s	a	α	β	v	
Algébrico	10^{-2}	10^{-5}	1	0,3	2	1	$f(M_{eco})$	

A matriz de velocidade U_{ij} utilizada nas imagens de ecocardiografia pelo método *level-set* orientado por gradiente permite a detecção de bordas quando é simplesmente igual à imagem original, não sendo submetida esta a qualquer pré-processamento, de modo que $U_{ij}^{eco} = I_{ij}$.

Conforme exposto na seção 5.1.1, o mapa de contornos utilizado pelos contornos ativos

algébricos nas imagens de ecocardiografia é dado por:

$$M_{eco} = \alpha \nabla I + \beta [\nabla I * G_{n_{MAPA} \times n_{MAPA}}(\sigma_{MAPA})], \quad (7.1)$$

em que $n_{MAPA} = 100$, $\sigma_{MAPA} = 30$ e

$$f(M_{ECO}) = \frac{1}{[1 + M_{eco}(X(i), Y(i))]^3}. \quad (7.2)$$

Com o objetivo de analisar mudanças nos resultados decorrentes de diferentes locais de inicializações, todos os métodos são testados a partir de uma inicialização do contorno próxima ao ventrículo esquerdo e de outra inicialização próxima aos pontos extremos da imagem. Em seguida, os métodos são aplicados em outras imagens da sístole e da diástole do ventrículo esquerdo, visando avaliar sua utilidade para fins médicos. Finalmente, é realizada a comparação do método considerado mais adequado ao padrão-ouro fornecido por especialistas.

Neste Capítulo, para melhor visualização dos resultados, esses são expostos através dos negativos das imagens de ecocardiograma. Então, diferentemente do Capítulo anterior, os contornos finais obtidos pelo método *level-set* orientado por gradiente são mostrados em azul claro, pelo *level-set* orientado por regiões em rosa e pelo método dos contornos ativos algébricos em vermelho. Excepcionalmente, na seção 7.4 os contornos fornecidos pelo método *level-set* orientado por gradiente são mostrados na cor preta para sua melhor identificação.

7.2 Resultados com Inicialização Próxima ao Ventrículo Esquerdo

A evolução dos contornos resultantes dos métodos *level-set* orientados por gradiente e regiões e MCA algébrico é mostrada nas Figuras 7.2, 7.3 e 7.4 respectivamente. No caso dos métodos *level-set*, a inicialização do contorno se dá sobre as bordas do feixe de ultrassom. Para o MCA algébrico, por sua vez, o contorno é inicializado dentro da cavidade do ventrículo esquerdo.

7.3 Resultados com Inicialização Próxima aos Pontos Extremos da Imagem

A evolução dos contornos resultantes para cada um dos métodos apresentados é mostrado nas Figuras 7.5, 7.6 e 7.7 respectivamente. Os contornos são inicializados em pontos próximos aos extremos da imagem. Especificamente neste teste, o parâmetro s inerente ao MCA algébrico, possui sinal negativo, já que o contorno se contrai. Os resultados obtidos a partir do teste em questão fornecem um forte indício do comportamento de cada método para uma inicialização automática.

7.4 Resultados de Segmentação na Sístole e na Diástole

Os resultados finais de segmentação do ventrículo esquerdo em sua sístole obtidos por cada um dos métodos são mostrados nas Figuras 7.8, 7.10 e 7.12. Por sua grande dependência às condições iniciais, o método dos contornos ativos algébricos é inicializado dentro da cavidade do ventrículo esquerdo, enquanto os outros dois métodos são inicializados nos pontos extremos da imagem.

A segmentação do ventrículo esquerdo em sua diástole obtida por cada método é mostrada nas Figuras 7.9, 7.11 e 7.13. Os métodos são novamente inicializados como nas imagens da sístole do ventrículo esquerdo.

7.5 Comparação dos Resultados com o Padrão-Ouro

Com o objetivo ilustrar o paralelo entre os resultados obtidos pelo MCA algébrico e os resultados esperados, este método é aplicado a 4 pares de imagens de ecocardiografia. Cada um destes pares corresponde a um diferente paciente, sendo composto por uma imagem do final da sístole do VE e por outra do final da diástole do VE de um mesmo ciclo cardíaco, totalizando 8 imagens.

A título exemplificativo, os resultados são mostrados nas Figuras 7.14, 7.15, 7.16 e 7.17. Para comparar quantitativamente estes resultados com os padrões-ouro, é utilizada a métrica do erro médio quadrático (EMQ) da área. Nesse caso, o EMQ coincide com a razão entre a quantidade de *pixels* rotulados erroneamente como pertencentes ou não à região de interesse e a quantidade total de *pixels*. Em outras palavras, o EMQ da área

informa a frequência amostral de um erro de classificação. A medida do EMQ em cada uma destas Figuras é mostrada na Tabela .

Tabela 7.2: Erro Médio Quadrático da Área

	EMQ
Figura 7.14 (a)	7,0135e-3
Figura 7.14 (b)	1,5257e-2
Figura 7.15 (a)	4,2620e-3
Figura 7.15 (b)	1,8620e-2
Figura 7.16 (a)	7,4357e-3
Figura 7.16 (b)	1,5683e-2
Figura 7.17 (a)	7,8798e-3
Figura 7.17 (b)	1,3685e-2

Apesar de informativo quanto a taxa de acerto do MCA algébrico, o EMQ da área não é utilizado como métrica de desempenho por outros métodos que se apliquem às mesmas imagens, e, portanto, não pode ser parâmetro de comparação com os mesmos. Assim, já que não é possível saber se os valores na Tabela ?? são aceitáveis o MCA Algébrico é comparado ao método *PSnakes*. Para realizar essa comparação utiliza-se uma medida de distância entre *pixels* (ALEXANDRIA, 2011).

A exemplo do procedimento utilizado para medir o desempenho do método *PSnakes*, são considerados dois contornos: o contorno de referência, ou padrão-ouro, C_r e o contorno resultante da segmentação C_s . Conforme mostrado na Figura 7.1, a partir do centróide P_i do objeto, são traçadas N retas f_i que guardam entre si a mesma distância angular. Cada reta f_i intercepta o contorno C_r no ponto C_{ri} e o contorno C_s no ponto C_{si} . O valor de d_i é calculado através da diferença da distância euclidiana entre os pontos C_{ri} e C_{si} e o centróide P_i (ALEXANDRIA, 2011).

Como d_i pode assumir valores negativos, o cálculo de sua média aritmética pode conduzir à conclusão viciosa da inexistência de erros de segmentação. Então, a métrica utilizada para comparação é o Erro Médio Quadrático (EMQ) da distância, dado por (ALEXANDRIA, 2011):

$$EMQ = \sqrt{\frac{1}{N} \sum_{i=1}^N d_i^2} \quad (7.3)$$

Para fins de comparação com o *PSnakes*, o contorno c_0 abordado na seção 5.1, é deslocado de modo tal que seu centróide P_i permaneça na origem dos eixos ortogonais. Deste modo, os pontos do contorno só se movem na direção radial em relação ao centróide P_i , permanecendo sobre uma mesma reta f_i .




Figura 7.1: medida de distância d_i entre o contorno de referência C_r e o contorno resultante da segmentação C_s .

A inicialização utilizada para segmentar o padrão-ouro é a mesma utilizada para segmentar o VE, bastando, para obter os valores de d_i , calcular as distâncias entre pontos de mesmo índice dos contornos C_r e C_s . Os contornos do método *PSnakes* são inicializados próximos às paredes do VE. Do mesmo modo ocorre com os contornos iniciais do MCA Algébrico, consistindo estes últimos em retângulos interiores a cavidade ventricular.

O EMQ da distância é utilizado para comparar os resultados obtidos pelo MCA Algébrico mostrados nas imagens 7.14 a 7.17 com os obtidos pelo método *PSnakes* para as mesmas imagens (ALEXANDRIA, 2011). Os valores de EMQ da distância obtidos para cada uma das imagens são expostos na Tabela 7.3.

Tabela 7.3: Erro Médio Quadrático da Distância

	PSnakes	MCA Algébrico
Figura 7.14 (a)	6,10	4,02
Figura 7.14 (b)	8,93	9,64
Figura 7.15 (a)	9,37	3,48
Figura 7.15 (b)	6,33	9,50
Figura 7.16 (a)	8,22	3,53
Figura 7.16 (b)	8,45	5,40
Figura 7.17 (a)	7,40	10,41
Figura 7.17 (b)	9,05	6,71

7.6 Conclusão do Capítulo

Os resultados obtidos pela aplicação de um mesmo método *level-set* sobre as imagens de ecocardiografia presentes no capítulo, uma por vez, tanto a partir de uma inicialização nas bordas do feixe de ultrassom, quanto a partir de outra inicialização mais geral, se revelam semelhantes. Por outro lado, observando-se as Figuras 7.4 (c) e 7.7 (c), nas quais os resultados são notadamente diferentes, resta evidente uma maior dependência à inicialização dos contornos ativos algébricos em relação aos métodos *level-set*.

Além disso, como definido nas Equações 7.1 e 7.2, faz-se necessária por parte dos contornos ativos algébricos, no caso de imagens de ecocardiografia, uma manipulação adicional das mesmas para a construção de um mapa de contornos adequado, o que não ocorre com os métodos *level-set*, nos quais as imagens em questão são utilizadas diretamente.

Ainda em termos comparativos, os métodos *level-set* são capazes de detectar, com maior precisão e eficiência, detalhes que se encontrem na área percorrida pela frente propagante, inclusive aqueles não pertencentes à região de interesse, tais como números, algarismos e escalas. Este resultado se explica pela capacidade do método *level-set* de segmentar vários objetos por imagem e pela independência por parte do método de pontos de controle a partir dos quais o contorno se movimenta.


Todavia, como é possível observar na Figuras 7.18 e 7.19, nas quais as paredes que delimitam a área ocupada pelo ventrículo esquerdo são indicadas por um médico especialista, esta câmara cardíaca possui apenas um contorno, fato que constitui uma verdade de campo, ou seja, é considerado cientificamente verdadeiro. Desse modo, já que os métodos *level-set* detectam as várias bordas presentes na imagem, os resultados por estes fornecidos não estão de acordo padrão-ouro apontado por um médico especialista. Assim, não obstante o fato de possuírem mais características interessantes para segmentação de propósito geral que os contornos ativos algébricos, como maior independência à inicialização e capacidade de segmentar vários objetos, os métodos *level-set* avaliados não forneceram resultados adequados para o auxílio ao diagnóstico médico do modo como foram aplicados. Portanto, conclui-se com base nos experimentos que, dentre os métodos avaliados e do modo como estes foram aplicados, os contornos ativos algébricos são os mais adequados para realizar a segmentação do ventrículo esquerdo nas imagens de ecocardiografia utilizadas. Além disso, nas imagens testadas, o MCA Algébrico possui resultados equiparáveis ao método *PSnakes*, como mostrado na Tabela 7.3.

No entanto, algumas ressalvas devem ser feitas. Comumente, os contornos apontados pelos médicos como paredes do ventrículo esquerdo não podem ser detectados pelos métodos *level-set* pelo simples fato não estarem presentes nas imagens, sendo sua indicação fundamentada muito mais na experiência profissional adquirida pelos mesmos nesta especialidade do que propriamente na informação presente em tais imagens.


Além disso, a conformidade dos resultados obtidos pelos contornos ativos algébricos com os padrões-ouro ocorre devido às limitações deste método de segmentar objetos com concavidades e com bordas descontínuas como mostram as Figuras 6.5 (b) e 6.3 (c). Estas limitações fazem com que o contorno, quando inicializado dentro do objeto, se acomode apenas a suas bordas interiores, segmentando, ao invés do próprio objeto, sua área interior, o que, no caso de imagens do VE, é uma característica interessante.

De todo modo, um paralelo das Figuras 6.4 (d) e 7.2 (c) com as Figuras 6.5 (b) e 7.4 (c) ilustra a maior adequação dos contornos ativos algébricos à segmentação do ventrículo esquerdo nas imagens de ecocardiografia a despeito de sua menor sofisticação. Assim, já que as paredes do ventrículo esquerdo aparecem como bordas descontínuas nas imagens de ultrassom, mesmo sendo este uma câmara fechada, a limitação apontada no método dos contornos ativos algébricos pode ser uma característica desejável para manter um único contorno dentro da região de interesse, fornecendo resultados de acordo com os padrões-ouro.


Assim, devido ao fato de o método dos contornos ativos algébricos ser, dentre os testados, o único avaliável por uma métrica que leva em consideração o padrão-ouro, os métodos não são comparados entre si quantitativamente.



(a)




(b)




(c)


Figura 7.2: resultado obtido pelo método *level-set* orientado por gradiente após (a) inicialização nas bordas do feixe de ultrassom (b) 7 iterações e (c) 15 iterações.



(a)



(b)



(c)

Figura 7.3: resultado obtido pelo método *level-set* orientado por regiões após (a) inicialização nas bordas do feixe de ultrassom (b) uma iteração e (c) 3 iterações.









Figura 7.4: resultado obtido pelo MCA algébrico após (a) inicialização dentro da cavidade do ventrículo esquerdo , (b) 25 iterações e (c) 100 iterações.



(a)




(b)




(c)


Figura 7.5: resultado obtido pelo método *level-set* orientado por gradiente após (a) inicialização nos pontos extremos da imagem, (b) 7 iterações e (c) 20 iterações.



(a)




(b)




(c)


Figura 7.6: resultado obtido pelo método *level-set* orientado por regiões após (a) inicialização nos pontos extremos da imagem, (b) 4 iterações e (c) 20 iterações.



(a)



(b)



(c)

Figura 7.7: resultado obtido pelo MCA algébrico após (a) inicialização nos pontos extremos da imagem, (b) 5 iterações e (c) 25 iterações.




Figura 7.8: resultado obtido pelo método *level-set* orientado por gradiente aplicado a imagem da sístole do ventrículo esquerdo após 50 iterações.




Figura 7.9: resultado obtido pelo método *level-set* orientado por gradiente aplicado a imagem da diástole do ventrículo esquerdo após 50 iterações.

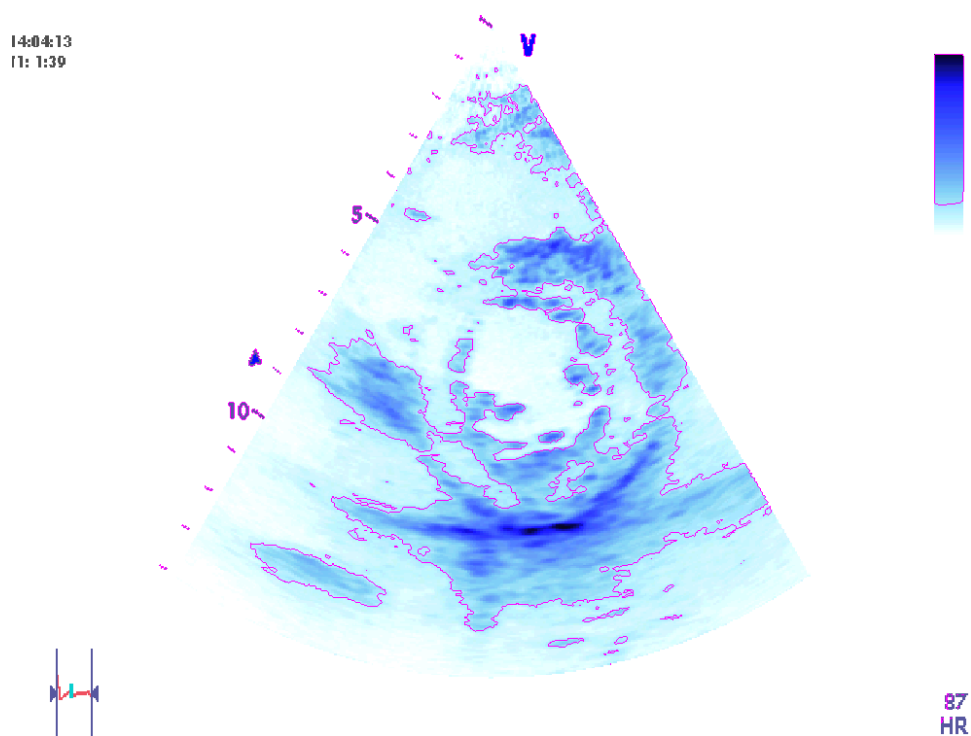


Figura 7.10: método *level-set* orientado por regiões aplicado a imagem da sístole do ventrículo esquerdo após 3 iterações.

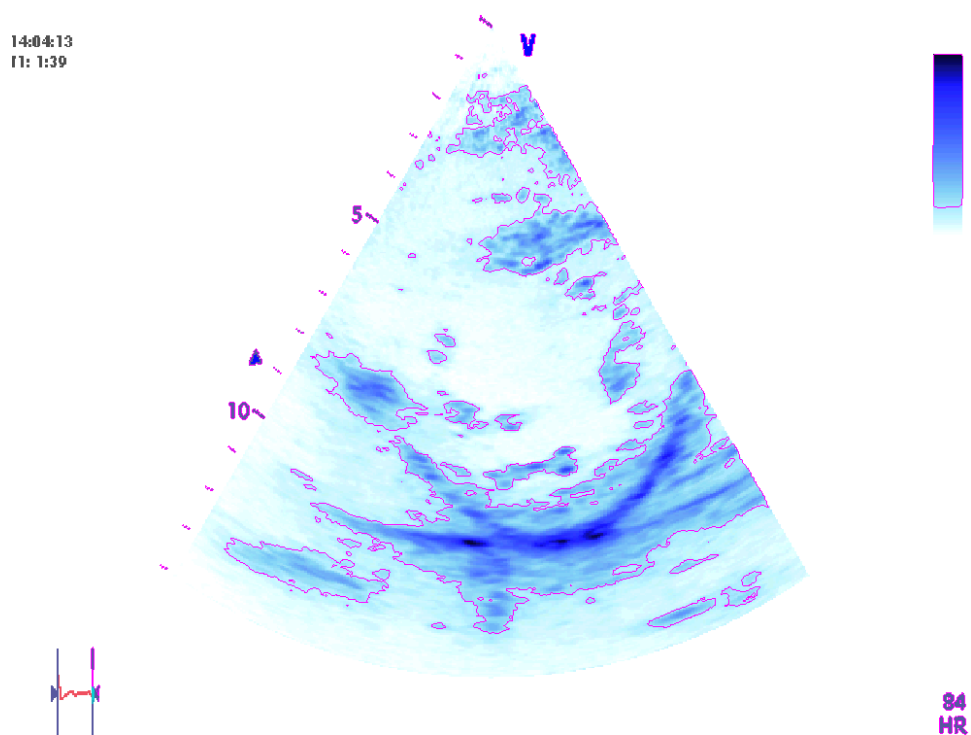


Figura 7.11: resultado obtido pelo método *level-set* orientado por regiões aplicado a imagem da diástole do ventrículo esquerdo após 3 iterações.




Figura 7.12: resultado obtido pelo MCA algébrico aplicado a imagem da sístole do ventrículo esquerdo após 25 iterações.






Figura 7.13: resultado obtido pelo MCA algébrico aplicado a imagem da diástole do ventrículo esquerdo após 25 iterações.




(a)




(b)

Figura 7.14: Comparação do resultado obtido pelo MCA algébrico (em vermelho) com o padrão-ouro fornecido por especialista (em verde) em uma (a) sístole e em uma (b) diástole.

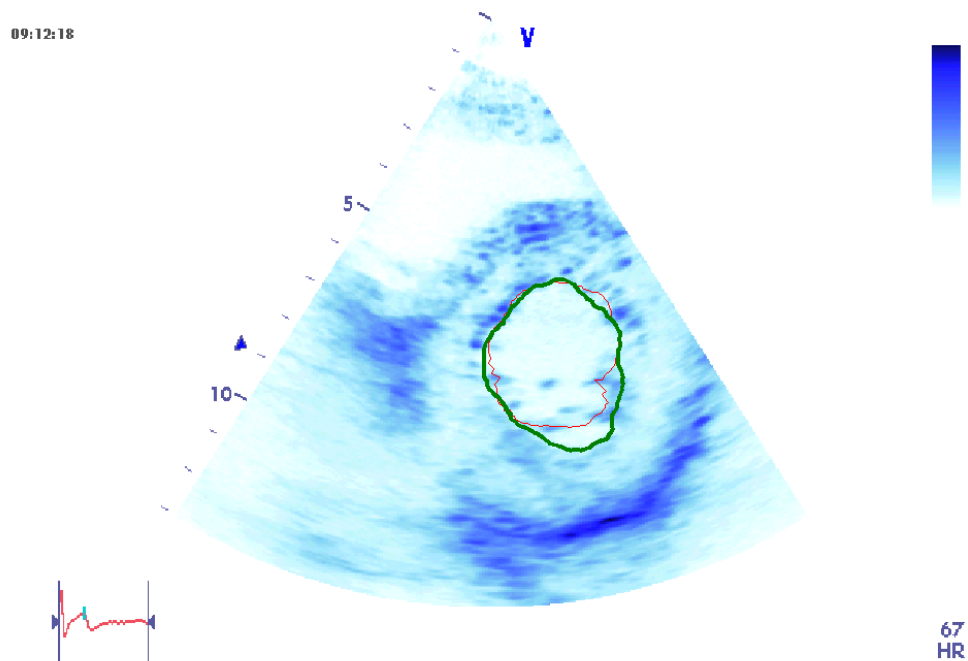


(a)




(b)

Figura 7.15: Comparação do resultado obtido pelo MCA algébrico (em vermelho) com o padrão-ouro fornecido por especialista (em verde) em uma (a) sístole e em uma (b) diástole.




(a)




(b)

Figura 7.16: Comparação do resultado obtido pelo MCA algébrico (em vermelho) com o padrão-ouro fornecido por especialista (em verde) em uma (a) sístole e em uma (b) diástole.



(a)



(b)

Figura 7.17: Comparação do resultado obtido pelo MCA algébrico (em vermelho) com o padrão-ouro fornecido por especialista (em verde) em uma (a) sístole e em uma (b) diástole.





Figura 7.18: (a) exemplo de imagem de ecocardiograma na sístole; (b) padrão-ouro (em verde) apontado por médico especialista.





Figura 7.19: (a) exemplo de imagem de ecocardiograma na diástole; (b) padrão-ouro (em verde) apontado por médico especialista.

Capítulo 8

Conclusão e Trabalhos Futuros

Neste trabalho foram implementados, testados e avaliados em imagens sintéticas e imagens extraídas de exames de ecocardiografia dois métodos *level-set*, um orientado por gradiente e outro orientado por regiões, bem como uma nova variação dos contornos ativos tradicionais, o método dos contornos ativos algébricos. Além disso, foram propostas como contribuições à literatura as seguintes melhorias:

- filtragem do fluxo Hamiltoniano presente no método *level-set* orientado por gradiente por uma janela gaussiana que suaviza o campo gradiente através do qual o contorno se propaga, aumentando a área coberta pelo contorno a cada iteração e, conseqüentemente, a velocidade do método;
- incorporação de uma função sinal ao método *level-set* orientado por gradiente, a qual controla a direção radial do contorno, ou seja, sua expansão ou contração;
- concepção de um método de contornos ativos algébricos que prescinde de buscas e comparações, movendo o contorno por meio apenas de operações algébricas de mudança de escala e
- superposição de mapas de contorno para prover aos contornos ativos tradicionais um aumento na área de influência do contorno sem perda de precisão na segmentação.

Conclui-se acerca dos métodos testados, com base nos experimentos, que o método dos contornos ativos algébricos possui maior dependência à inicialização em relação aos métodos *level-set* e apresenta limitação na segmentação de objetos com concavidades e bordas descontínuas. Também verifica-se que, conforme previsão teórica, os métodos *level-set* são capazes de realizar naturalmente divisões e unificações dos contornos, o que permite a segmentação de vários objetos em uma só imagem. Apesar da limitação em

segmentar imagens com grandes regiões homogêneas, o método *level-set* orientado por regiões apresentou maior tolerância à presença de ruído, sendo, porém, o *level-set* orientado por gradiente superior aos demais em todos os outros testes realizados com imagens sintéticas.

No entanto, apesar do desempenho inferior nos testes de segmentação para propósito geral, os contornos ativos algébricos revelaram-se, dentre os três métodos avaliados, o único método capaz de segmentar o ventrículo esquerdo em imagens de ecocardiografia de acordo com o padrão-ouro fornecido por especialistas.

Em um contexto geral, a utilização do MCA algébrico é recomendável quando há apenas uma região de interesse em imagens que possuam alta relação sinal-ruído. Nesta região, é necessário que os *pixels* sejam contíguos e que o contorno seja único, contínuo e arredondado, não possuindo concavidades acentuadas. Assim, o MCA algébrico pode ser utilizado, por exemplo, para segmentar o disco óptico em imagens do globo ocular a fim de detectar lesões na retina. Esta possibilidade é ilustrada na Figura 8.1.



Figura 8.1: segmentação do disco óptico resultante da aplicação do MCA algébrico (contorno em azul) em imagem do globo ocular.


Em aplicações em que possa haver múltiplas regiões de interesse, e que requeiram uma segmentação com maior nível de detalhamento, os métodos *level-set* são mais recomendáveis.

Conforme exposto na seção 3.4, a escolha dos parâmetros n e σ da janela gaussiana para a filtragem do Hamiltoniano no método *level-set* orientado por gradiente deve respeitar o compromisso entre o desempenho e a precisão do método. Assim, sugere-se para trabalhos


futuros uma metodologia para encontrar valores adequados para estes parâmetros.

Como dito no Capítulo 7, é comum que as informações necessárias para a detecção das paredes do ventrículo esquerdo não estejam presentes nas imagens de ecocardiografia. Nessas condições, obter resultados que concordem precisamente com o padrão-ouro utilizando apenas algoritmos não-supervisionados, ou seja, que não utilizam dados anatômicos, é uma tarefa complexa. Dessa forma, parâmetros extraídos do padrão-ouro a disposição podem ser utilizados no treinamento de um algoritmo supervisionado para segmentação do ventrículo esquerdo em trabalhos futuros.

Outra possibilidade superveniente, é a aplicação dos métodos *level-set* em outras imagens médicas por meio de cujas informações, por si só, se possa realizar uma segmentação rigorosamente de acordo com o apontado como verdade de campo. Uma exemplificação da potencialidade desses métodos é demonstrada na Figura 8.2, que mostra o resultado da segmentação do pulmão e do tórax em uma imagem de tomografia computadorizada.



(a)



(b)

Figura 8.2: (a) imagem original de uma tomografia computadorizada do tórax (b) resultado da segmentação do pulmão e tórax utilizando o método *level-set* orientado por gradiente.

Referências Bibliográficas

ALBUQUERQUE, V. H. C. *Sistemas de Visão Computacional Para a Caracterização da Grafita Usando Microfotografias*. Dissertação (Mestrado) — Universidade Federal do Ceará, Fortaleza, Dezembro 2007.

ALEXANDRIA, A. R. *Sistema de Reconhecimento Óptico de Algarismos para Medidores Convencionais de Energia*. Dissertação (Mestrado) — Univesidade Federal do Ceará, Fortaleza, junho 2005.

ALEXANDRIA, A. R. *PSnakes: Método de Contornos Ativos Radiais Usando Energia Híbertiana Para Segmentação do Ventrículo Esquerdo em Imagens de Ultrassom*. Tese (Phd Thesis) — Universidade Federal do Ceará, Setembro 2011.

ALEXANDRIA, A. R. et al. Método de contornos ativos psnakes aplicado em imagens de ecocardiograma de eixo curto para cálculo de fração de ejeção. *Revista Brasileira de Engenharia Biomédica*, v. 27, p. 147–162, 2011.

BARRETO, G. A. *Unsupervised neural networks for temporal sequence processing*. Dissertação (Mestrado) — Department of Electrical Engineering, University of São Paulo, São Carlos, SP, 1998. (in portuguese).

BARROS, A. C. S. *Análise Comparativa de Técnicas de Detecção de Movimento e Rastreamento de Objetos em Vídeo Digital usando Dispositivos Móveis*. Dissertação (Mestrado) — Universidade Federal do Ceará, Fortaleza, Novembro 2010.

BOUHOURS, A. *Segmentação do ventrículo em Ecocardiogramas usando contornos ativos*. Dissertação (Mestrado) — Universidade Federal do Ceará, Fortaleza, 2006.

CAVALCANTE, T. S. *Técnica de Segmentação Automática das Vias Aéreas em Imagens de Tomografia Computadorizada*. Dissertação (Mestrado) — Universidade Federal do Ceará, Fortaleza, Janeiro 2010.

CHALANA, V. et al. A multiple active contour model for cardiac boundary detection on echocardiographic sequences. *Revista Brasileira de Engenharia Biomédica*, v. 15, n. 3, p. 290–298, 1996.

CHAN, T.; VESE, L. Active contours without edges. *IEEE TRANSACTIONS ON IMAGE PROCESSING*, p. 266–277, 2001.

CHEN, Q. et al. Parametric active contours for object tracking based on matching degree image of object contour points. *Pattern Recogn. Lett.*, Elsevier Science Inc., New York, NY, USA, v. 29, n. 2, p. 126–141, jan. 2008.

COSTA, L. H. L. Desenvolvimento de um sistema semi-automático para determinação de durezas brinell e vickers utilizando técnicas de processamento e análise de imagem. 2008.

DENZLER, J.; NIEMANN, H. Active rays: A new approach to contour tracking. *International Journal of Computing and Information Technology*, v. 4, p. 9–16, 1996.

ENGQUIST B.; OSHER, S. Stable and entropy-satisfying aproximations for transonic flow calculations. *Math. Comp.*, v. 34, p. 45, 1980.

FÉLIX, J. H. S. *Sistema de Visão Computacional Para Detecção e Quantificação de Enfisema Pulmonar*. Dissertação (Mestrado) — Universidade Federal do Ceará, 2007.

FELIX, J. H. S. et al. Novo método de contornos ativo baseado na transforma de hilbert radial. *V Congreso Latinoamericano de Ingeniería Biomédica, 2011, Havana. V Latin American Congress on Biomedical Engineering CLAIB 2011, IFMBE Proceedings.*, v. 33, p. 1–4, 2011.

FENG, W. et al. A dual propagation contours technique for semi-automated assessment of systolic and diastolic cardiac function by cmr. *Journal of Cardiovascular Magnetic Resonance*, v. 11, p. 1–13, 2009.

FILHO, B. M. et al. Estratificando o risco na angina instável com a ecocardiografia sob estresse com dobutamina. *Arquivos Brasileiros de Cardiologia*, p. 259–64, 2006.

FILHO C.; MOURA, L. C. M. C. Revisão sobre métodos de segmentação 2d do ventrículo esquerdo / review of left ventricle 2d segmentation methods. *Revista Brasileira de Engenharia Biomédica*, v. 15, p. 141–148, 1999.

FILHO, O. M.; NETO, H. V. *Processamento Digital de Imagens*. Rio de Janeiro: BRASPORT Livros e Multimídia Ltda, 1999.

FILHO, P. R. *MCA Crisp: Nova Técnica de Segmentação dos Pulmões em Imagens de Tomografia Computadorizada baseada no Método de Contorno Ativo*. Dissertação (Mestrado) — Universidade Federal do Ceará, 2010.

FREITAS, R. F. *Sistema de Rastreamento da Mão Humana Utilizando Visão Artificial para Aplicações Embarcadas*. Dissertação (Mestrado) — Universidade Federal do Ceará, Fortaleza, Abril 2011.

GONZALEZ, R. C.; WOODS, R. *Digital Image Processing*. 3a. ed. New Jersey: Pearson Prentice Hall, 2007. ISBN 0-13-168728-x.

HANSEGARD J.; URHEIM S.; LUNDE, K. R. S. Constrained active appearance models for segmentation of triplane echocardiograms. *IEEE TRANSACTIONS ON MEDICAL IMAGING*, v. 60, p. 1391–1400, 2007.

HAYKIN, S. *Neural Networks - A Comprehensive Foundation*. USA: Macmillian College Publishing Company Inc, 1994.

HAYKIN, S.; VEEM, B. V. *Sinais e Sistemas*. 1.ed. ed. Porto Alegre: Bookman, 2001. ISBN 85-7307-741-7.

HEIDJEN, F. V. *Image based measurement systems object recognition*. England: John Wiley and Sons Ltda, 1994.

ITAI Y.; KIM, H. I. S. A segmentation method of lung areas by using snakes and automatic detection of abnormal shadow on the areas. *International Journal of Innovative Computing Information and Control*, v. 3, p. 277–284, 2007.

JAIN A.K.; MOHIUDDIN, J. Artificial neural networks: A tutorial. *IEEE Computer*, v. 29, p. 31–44, 1996.

JÚNIOR, J. A. C. S. *Técnicas de Segmentação do Ventrículo Esquerdo Utilizando Contornos Ativos (snakes) em Imagens Digitais de Ecocardiograma*. Dissertação (Mestrado) — Universidade Federal do Ceará, Fortaleza, Janeiro 2010.

KASS, M.; WITKIN, A.; TERZOPOULOS, D. Snakes: active contours models. *International Journal of Computer Vision*, v. 1, n. 4, p. 321–331, january 1988.

KICHENASSAMY, S. et al. Gradient flows and geometric active contour models. In: *Proceedings of the Fifth International Conference on Computer Vision*. Washington, DC, USA: IEEE Computer Society, 1995. (ICCV '95), p. 810–. ISBN 0-8186-7042-8. Disponível em: <<http://dl.acm.org/citation.cfm?id=839277.840023>>.

- LANGER, L. S. Instability and patterns formation in crystal growth. *Rev. Modern Phys.*, p. 52, 1980.
- LEUNG, K. Y. E. et al. Sparse appearance model based registration and segmentation of 3d echocardiographic images. *IEEE Ultrasonics Symposium*, p. 2413–2416, 2006.
- LI, C. et al. Minimization of region-scalable fitting energy for image segmentation. *IEEE TRANSACTIONS ON IMAGE PROCESSING*, v. 17, n. 10, p. 1940–1949, 2008.
- _____. Level set evolution without re-initialization: A new variational formulation. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, v. 1, p. 430–436, 2005.
- LOPES, E. C. *Detecção de Faces e Características Faciais*. Dissertação (Mestrado) — Pontifícia Universidade Católica do Rio Grande do Sul, 2003.
- MACEACHERN, L. A.; MANKU, T. Genetic algorithms for active contour optimization. *IEEE International Symposium on Circuits and Systems*, v. 4, n. 229-232, 1998.
- MALLADI, R.; SETIAN, J. A.; VEMURI, B. C. Shape modeling with front propagation: A level set approach. *IEEE Transaction on PAMI*, v. 17, p. 158–175, 1995.
- MARKMAN, B. F. *A ecocardiografia de estresse com dobutamina na doença coronária*. Dissertação (Mestrado) — Faculdade de Medicina da Universidade Federal de Pernambuco, Recife, Setembro 1997.
- MARKSTEIN, G. H. Experimental and theoretical studies of flame front stability. *J. Aero. Sci.*, p. 199, 1951.
- MCINERNEY, T.; TERZOPOULOS, D. Deformable models. *Medical Images Analysis: A Survey*, n. 91-108, 1996.
- _____. T-snakes: Topology adaptive snakes. *Medical Image Analysis*, v. 4, n. 2, p. 73 – 91, 1999.
- MESQUITA, V. A. Segmentação automática do ventrículo esquerdo em imagens de ecocardiografia usando contornos ativos (snakes). 2009.
- OSHER, S.; FEDKIW, R. *Level Set Methods and Dynamic Implicit Surfaces*. [S.l.]: Springer Verlag, 2003.

- OSHER, S.; SETHIAN, J. A. Fronts propagating with curvature dependent speed: Algorithms based on hamilton-jacobi formulations. *Journal of Computational Physics*, v. 79, p. 12–49, 1988.
- OTTO, C. M. *Textbook of clinical echocardiography*. 3. ed. Philadelphia: Elsevier Saunders, 2004.
- PITAS, I. *Digital Image Processing Algorithms and Applications*. 1st.. ed. [S.l.]: Thomson Learning, 2000.
- PRATT, W. K. *Digital Image Processing*. 4. ed. Los Altos, CA: John Wiley and Sons, Inc, 2007. ISBN 978-0-471-76777-0.
- PREDINI H.; SCWART, W. R. *Análise de Imagens Digitais*. [S.l.]: Thomson Learning, 2007.
- QIAN, K. O. Lax-friedrichs sweeping scheme for static hamilton-jacobi equations. *Journal of Computation Physics*, p. 367 – 391, 2003.
- SETHIAN, J. A. Numerical algorithms for propagating interfaces: Hamilton-jacobi equation and conservation laws. *J. Differential Geometry*, p. 131 – 161, 1990.
- _____. Theory, algorithms and applications of level-set methods for propagating interfaces. *Acta Numerica*, v. 5, p. 309 – 395, 1996.
- XU, C.; PRINCE, J. Snakes, shapes, and gradient vector flow. *IEEE TRANSACTIONS ON IMAGE PROCESSING*, v. 7, n. 3, p. 359–369, 1998.
- XU, C.; YEZZI, A.; PRINCE, J. L. On the relationship between parametric and geometric active contours. *34th Asilomar Conference on Signals, Systems, and Computers*, p. 483 – 489, 2000.
- YEZZI, A. A geometric snake model for segmentation of medical imagery. *IEEE TRANSACTIONS ON MEDICAL IMAGING*, v. 16, p. 199 – 209, 1997.