Serviço de Pós-Graduação EESC/USP

EXEMPLAR REVISADO

Data de entrada no Serviço... 01 / 08 / 2005

Ass.: *[assinatura]*

Eduardo Rafael Llapa Rodríguez

SEGMENTAÇÃO DE FRONTEIRAS EM IMAGENS MÉDICAS VIA
CONTORNOS DEFORMÁVEIS ATRAVÉS DO FLUXO RECURSIVO
DO VETOR GRADIENTE

Dissertação apresentada à Escola de Engenharia de
São Carlos da Universidade de São Paulo, como
parte dos requisitos para a obtenção do Título de
Mestre em Engenharia Elétrica.

Orientador: Professor Dr. Adilson Gonzaga

DEDALUS - Acervo - EESC

31100052217

São Carlos
2005

FOLHA DE JULGAMENTO

Candidato: Engenheiro **EDUARDO RAFAEL LLAPA RODRÍGUEZ**

Dissertação defendida e julgada em 08-07-2005 perante a Comissão Julgadora:

Prof. Associado **ADILSON GONZAGA (Orientador)**
(Escola de Engenharia de São Carlos/USP) APROVADO

Prof. Dr. **EVANDRO LUIS LINHARI RODRIGUES**
(Escola de Engenharia de São Carlos/USP) APROVADO

Prof. Dr. **JOSE FERNANDO COLAFÊMINA**
(Faculdade de Medicina de Ribeirão Preto/USP) APROVADO

Prof. Associado **HOMERO SCHIABEL**
Coordenador do Programa de Pós-Graduação em Engenharia
Elétrica

Prof. Associado **MARCIO ROBERTO SILVA CORREA**
Vice-Presidente da Comissão de Pós-Graduação, em Exercício

À minha bênção: Os meus pais Isabel e Albino, minha irmã Eliana, meu cunhado Carlos e o meu sobrinho Thiago.

Agradecimentos

Eu gostaria de agradecer ao meu orientador Dr. Adilson Gonzaga, pela oportunidade, guia e estímulo na realização do curso de mestrado neste país; ao Dr. Odemir Bruno (ICMC - USP) pelas valiosas tardes de troca de idéias, opiniões e conceitos, com vista ao avance e fortalecimento da forma final desta dissertação; ao Dr. Chenyang Xu (*Johns Hopkins University*) pelo tempo e apoio técnico; ao Dr. Ernesto Cuadros (*Sociedad Peruana de Computación*) pela visão criativa e sugestões nos assuntos técnicos e não técnicos; ao Dr. Alexandre Xavier Falcao (IC - Unicamp) pela muitas apreciações e assistência de conceitos; ao Dr. Sabino J. Ferreira (Estatística - UFMG) pelas sugestões e revisões durante o percurso da pesquisa; ao Dr. Joachim Weickert (*Department of Computer Science - University of Copenhagen*) pelo apoio bibliográfico transmitido e o fornecimento da sua produção científica que permitiram modelar e esclarecer dúvidas no decorrer da pesquisa; ao Dr Homero Schiabel por compartilhar sua experiência e conhecimentos nas horas de aula e o desafio constante que significava participar das suas disciplinas, as quais me fizeram escolher o tratamento de imagens médicas; ao Dr(c) José Carlos Pizolato Junior (EESC - USP) pelo apoio elegante, sincero e produtivo durante a revisão das múltiplas versões deste trabalho; ao Dr(c) Cesar Beltrán Castañon (IME - USP) pelo apoio nos primeiros passos na utilização do programa LATEX.

Eu gostaria de agradecer a os meus pais Albino Llapa Pérez e Isabel Rodríguez Tejada, pelo apoio econômico e emocional, sendo sempre meu suporte durante a realização deste trabalho.

Eu gostaria de agradecer a todos meus colegas e amigos que, com o dia a dia, modelaram e fortaleceram minha labor de pesquisador, fazendo da minha permanência na

Universidade de São Paulo uma experiência memorável. De forma particular, gostaria de agradecer ao Dr. Evandro Luís Linhari Rodrigues (EESC - USP) pelo constante interesse no desenvolvimento deste trabalho; à Dra. Maria Stela Veludo de Paiva (EESC - USP) pelo seu apoio incondicional e sincero; ao mestre Ricardo Soares Rubin (EESC - USP) pelas estimulantes discussões que me encorajaram a publicar os avances da minha pesquisa, ainda antes de qualificar.

Eu gostaria de agradecer a Marisa Helena R. Vicente Fortulan e Denise Hollupi da secretaria de Pós-graduação do departamento de Engenharia Elétrica, pelo apoio, esclarecimento das normas e a disposição que sempre encontrei em vocês.

Eu gostaria de agradecer finalmente a os meus amigos Dr(c) Alex Cuadros (ICMC - USP), Dr(c) Lizandro Sanches (ICMC - USP) e mestrando Juan Carlos Guillén (UFSCar) pelas discussões em casa a respeito deste trabalho, nas quais observei a necessidade de explicitar idéias e aprofundar conceitos em diversas seções do meu trabalho.

Resumo

LLAPA-RODRIGUEZ, E. R. (2005). Segmentação de fronteiras em imagens médicas via contornos deformáveis através do fluxo recursivo do vetor gradiente. Dissertação (Mestrado) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2005.

Devido à variação na qualidade e ao ruído nas imagens médicas, a aplicação de técnicas tradicionais de segmentação é geralmente ineficiente. Nesse sentido, apresenta-se um novo algoritmo a partir de duas técnicas: o modelo de contornos deformáveis por fluxo do vetor gradiente (*GVF deformable contours*) e a técnica de espaço de escalas utilizando o processo de difusão.

Assim, foi realizada uma revisão bibliográfica dos modelos que trabalham com os contornos deformáveis, os quais foram classificados em modelos paramétricos e geométricos. Entre os modelos paramétricos foi escolhido o modelo de contornos deformáveis por fluxo do vetor gradiente (GVF). Esta aproximação oferece precisão na representação de estruturas biológicas não observada em outros modelos.

Desta forma, o algoritmo apresentado mapeia as bordas (*edge map*) e aperfeiçoa a condução da deformação utilizando uma técnica baseada em operações recursivas. Com este cálculo apoiado no comportamento de espaço de escalas, obtém-se a localização e correção de sub-regiões do *edge map* que perturbam a deformação. Por outro lado, é incorporada uma nova característica que permite ao algoritmo realizar atividades de classificação. O algoritmo consegue determinar a presença ou ausência de um objeto de interesse utilizando um valor mínimo de deformação.

O algoritmo é validado através do tratamento de imagens sintéticas e médicas comparando os resultados com os obtidos no modelo tradicional de contornos deformáveis GVF.

Palavras-chave: processamento de imagens; imagens médicas; modelos deformáveis; contornos deformáveis; fluxo do vetor gradiente.

Abstract

LLAPA-RODRIGUEZ, E. R. (2005). Edge segmentation in medical images using the recursive gradient vector flow deformable contours. Dissertation (Master's degree) - Engineering School of São Carlos, University of São Paulo, São Carlos, 2005.

Due to the variation of the quality and noise in medical images, the classic image segmentation techniques are usually ineffective. In this work, we present a new algorithm that is composed of two techniques: the gradient vector flow deformable contours (GVF) and the scale-space technique using a diffusion process.

A bibliographical revision of the models that work with deformable contours was accomplished, they were classified in parametric and geometric models. Among the parametric models the gradient vector flow deformable contours (GVF) was chosen. This approach offers precision in the representation of biological structures where other models does not.

Thus, the algorithm improves the *edge map* to guide the deformation using recursive operations. With this estimation based on the behavior of the scale-space techniques it is realized, the localization and correction of sub-areas of the *edge map* that disturb the deformation. On the other hand, it was incorporated a new characteristic that allows the algorithm to accomplish classification activities. That is, the algorithm determines the presence or absence of a target object using a minimal deformation area.

Our method was validated on both, simulated images and medical images making a comparison with the traditional GVF deformable contours.

Keywords: image processing; medical imaging; deformable models; deformable contours; gradient vector flow.

Lista de Figuras

1.1	Variabilidade na qualidade das imagens, nas bordas e no ruído presente nas imagens médicas. A imagem esquerda apresenta uma angiografia da artéria carótida e a direita um ultra-som do abdômen.	2
1.2	A importância da localização do contorno inicial na aplicação dos modelos deformáveis tradicionais. Existe uma dependência direta da inicialização e a sua convergência.	4
2.1	O tratamento de ruído na segmentação de imagens médicas (ultra-som cardíaco do ventrículo esquerdo) utilizando modelos deformáveis.	9
2.2	A utilização dos contornos deformáveis numa (a) tomografia computadorizada do ventrículo esquerdo. (b) A imagem depois da aplicação do detector de bordas. (c) A inicialização do contorno deformável. (d)-(f) A procura da minimização de energia nas bordas do ventrículo esquerdo.	9
2.3	O modelo deformável Balão utilizado na procura das bordas do ventrículo esquerdo.	10
2.4	O resultado de aplicar <i>Matching</i> e rotulagem de estruturas, a partir do atlas deformável utilizando imagens por ressonância magnética do cérebro.	11
2.5	Tracking do movimento do ventrículo esquerdo durante um ciclo cardíaco (1-16), utilizando a força balão como modelo deformável.	13
3.1	O comportamento das forças internas e externas nos modelos deformáveis. Uma curva paramétrica é inicializada no domínio da imagem de interesse, e é deformada pela ação da energia interna (forças geradas na própria curva) e da energia externa (forças derivadas da imagem).	15

3.2	O desenvolvimento das pesquisas em modelos deformáveis a partir dos modelos paramétricos e geométricos.	16
3.3	O comportamento elástico que forma parte da energia interna do modelo deformável.	17
3.4	O comportamento rígido que forma parte da energia interna do modelo deformável.	18
3.5	A energia potencial ou energia externa $P(x, y)$, gerada a partir das bordas de uma imagem por ressonância magnética.	19
3.6	A utilização dos modelos deformáveis geométricos em imagens médicas, através de mudanças topológicas.	22
3.7	Uma curva como o conjunto de níveis. Da esquerda para a direita temos uma simples curva, a representação da função de conjunto de níveis onde o nível zero fica na região mais escura, e o mapa de altura do conjunto de níveis respectivamente.	24
3.8	O conjunto de nível zero divide-se em 2 curvas. Nesse momento a função de conjunto de níveis não é mais válida devido à mudança topológica que foi realizada.	25
4.1	A convergência do modelo deformável utilizando a força de pressão na procura das fronteiras objetivo, inicializando a deformação (a) no interior do objeto e (b) encerrando a borda objetivo.	30
4.2	A aplicação da força interativa numa (a) tomografia computadorizada. Em (b) observa-se que a deformação do modelo é influenciada pelos gradientes e pontos de referência identificados pelo especialista.	33
4.3	Um exemplo de campo de força potencial de distância em uma região côncava.	34
4.4	Um exemplo da aplicação do fluxo do vetor gradiente nos contornos deformáveis. (a) O campo da força fluxo do vetor gradiente e (b) o resultado da aplicação da força fluxo do vetor gradiente desde um contorno inicial circular.	36
4.5	Comportamento da convergência do <i>edge map</i> tradicional e no <i>edge map</i> (GVF) respectivamente, sendo aplicados numa região côncava.	37
5.1	Etapas da metodologia utilizada para a obtenção do modelo deformável RGVF.	40
5.2	Algoritmo do modelo deformável <i>Recursive Gradient Vector Flow</i> (RGVF).	41

5.3	Matriz bidimensional representativa da imagem, gerada no processo de aquisição.	42
5.4	Aplicação da técnica de espaço de escalas utilizando o processo de difusão em imagens sintéticas: (a) Imagem original de um octógono, e (b) o resultado do processo utilizado recursivamente.	43
5.5	Aplicação recursiva da técnica de espaço de escalas utilizando o processo de difusão em imagens médicas: (a) Imagem obtida através de ressonância magnética, e o resultado é observado em (b).	44
5.6	Resultado do pré-processamento de uma imagem sintética, utilizando em (a) só o filtro de Sobel, e em (b) a técnica de espaço de escalas utilizando o processo de difusão mais o filtro de Sobel.	44
5.7	Pré-processamento de uma imagem médica fazendo uso em (a) do filtro de Sobel, e em (b) a aplicação de espaço de escalas utilizando o processo de difusão ademais do filtro de Sobel.	45
5.8	Cálculo dos gradientes, após o pré-processamento numa imagem sintética. Em (a) apresenta-se o gradiente na direção x , e em (b) o gradiente na direção y da imagem.	46
5.9	Cálculo dos gradientes, após o pré-processamento numa imagem médica. Em (a) apresenta-se o gradiente na direção x , e em (b) o gradiente na direção y da imagem.	46
5.10	Solução de equilíbrio v_t do sistema de equações diferenciais parciais 5.1, aplicado nas coordenadas x e y	47
5.11	Aplicação da normalização dos vetores acima das soluções de v_t nas imagens sintética e médica respectivamente.	47
5.12	Na inicialização da curva é utilizada uma variável t com valores de 0 até 6.28 para o cálculo das coordenadas x e y como mostra-se a seguir: $x = \cos(t)$; $y = \sin(t)$	48
5.13	O processo de interpolação, é realizado mediante a adição de pontos onde a distância é maior a $D = 2$, e sendo feita uma remoção onde ela é menor a $D = 2$. A distância é calculada através da adjacência por borda entre os pixels (pontos) que formam a curva paramétrica.	48
5.14	Modificação das sub-regiões vizinhas à curva paramétrica que apresentam perturbações de direção. Em (a) é apresentada uma sub-região inicial, e (b) mostra a mesma sub-região modificada.	49

5.15	Processo de deformação aplicado recursivamente na busca por atingir a minimização $E(x)$. Em (a) apresenta-se a aplicação do modelo numa imagem sintética, e em (b) o comportamento do mesmo na imagem médica.	49
5.16	Processo de deformação utilizando o valor mínimo de deformação . Em (a) apresenta-se uma imagem de ultra-som. Em (b) é apresentado em forma gráfica o valor mínimo de deformação fornecido pelo usuário. Na imagem (c) observa-se a execução do processo de comparação (cálculo do centro de massa, e dos raios das curvas). Finalmente na imagem (d) apresenta-se a localização do objeto ao encontrar a minimização da curva $E(x)$ antes de atingir o valor mínimo de deformação.	50
5.17	Resultado da aplicação do modelo RGVF na procura da minimização da curva paramétrica $E(x)$ em uma imagem sintética: (a) Imagem sintética. (b) Imagem pré-processada. (c) Execução do processo de deformação. (d) Obtenção da borda do objeto de interesse.	51
5.18	Aplicação do modelo RGVF para a minimização da curva paramétrica $E(x)$ em imagens médicas: (a) Imagem médica a ser processada. (b) Imagem pré-processada. (c) Execução do processo de deformação. (d) Obtenção da borda do objeto de interesse.	52
5.19	Aplicação do modelo RGVF para detecção de objetos em imagens médicas: Em (a) é apresentada uma imagem de ultra-som, na qual observa-se a presença de um tumor, o qual é detectado como observa-se na figura (b). Já na figura (c) é avaliada uma imagem ultra-som sem presença de objetos de interesse, e em (d) observa-se a resposta da não existência de objetos maiores ao valor mínimo de deformação	53
6.1	Processo de detecção de fronteiras, aplicado numa imagem gerada a partir de ressonância magnética: (a) Imagem médica a ser processada. (b) Localização da curva inicial. (c) O <i>Edge map</i> do modelo RGVF, depois de ser aplicado de forma iterativa nas sub-regiões de interesse. (d) Bordas encontradas com o modelo RGVF, utilizando $\mu = 0.2$. (e) O <i>Edge map</i> do modelo GVF. (f) Borda final encontrada pelo modelo GVF.	55

6.2	Processo de detecção de fronteiras, aplicado numa imagem gerada a partir de raios X: (a) Imagem médica a ser processada. (b) Localização da curva inicial. (c) O <i>Edge map</i> do modelo RGVF, depois de ser aplicado de forma iterativa nas sub-regiões de interesse. (d) Bordas encontradas com o modelo RGVF, utilizando $\mu = 0.05$. (e) O <i>Edge map</i> do modelo GVF. (f) Borda final encontrada pelo modelo GVF.	56
6.3	Processo de detecção de fronteiras, aplicado numa imagem de tomografia computadorizada: (a) Imagem médica a ser processada. (b) Localização da curva inicial. (c) O <i>Edge map</i> do modelo RGVF, depois de ser aplicado de forma iterativa nas sub-regiões de interesse. (d) Bordas encontradas com o modelo RGVF, utilizando $\mu = 0.05$. (e) O <i>Edge map</i> do modelo GVF. (f) Borda final encontrada pelo modelo GVF.	57
6.4	Processo de detecção de fronteiras, aplicado numa imagem angiográfica: (a) Imagem médica a ser processada. (b) Localização da curva inicial. (c) O <i>Edge map</i> do modelo RGVF, depois de ser aplicado de forma iterativa nas sub-regiões de interesse. (d) Bordas encontradas com o modelo RGVF, utilizando $\mu = 0.08$. (e) O <i>Edge map</i> do modelo GVF. (f) Borda final encontrada pelo modelo GVF.	58
6.5	Processo de detecção de fronteiras, aplicado numa imagem de ultra-som: (a) Imagem médica a ser processada. (b) Localização da curva inicial. (c) O <i>Edge map</i> do modelo RGVF, depois de ser aplicado de forma iterativa nas sub-regiões de interesse. (d) Bordas encontradas com o modelo RGVF, utilizando $\mu = 0.4$. (e) O <i>Edge map</i> do modelo GVF. (f) Borda final encontrada pelo modelo GVF.	59
6.6	Imagem determinada como falso positivo na etapa de classificação da presença de nódulos.	60
6.7	Imagem classificada corretamente como verdadeiro positivo pelo processo de classificação.	60
A.1	Processo de binarização por <i>threshold</i>	69
A.2	Processo de equalização da imagem.	71
A.3	Máscaras de Sobel.	72
A.4	Determinação da magnitude e da direção da borda.	72
A.5	Aplicação dos operadores de Sobel sobre uma imagem.	73
A.6	Máscara de Laplace.	74
A.7	Aplicação do operador Laplaciano.	74

A.8	Processo de busca do contorno de uma imagem.	75
A.9	Processo de crescimento de região.	77
A.10	Processo de divisão e fusão de uma imagem.	78

Sumário

1	Introdução	1
1.1	Considerações iniciais	1
1.2	Motivação	3
1.3	Objetivos	5
1.4	Organização do trabalho	5
2	Modelos deformáveis na análise de imagens médicas	7
2.1	Considerações iniciais	7
2.2	Modelos deformáveis na segmentação de imagens	8
2.2.1	Incorporação de conhecimento <i>a priori</i>	10
2.3	<i>Matching</i>	11
2.4	<i>Motion tracking</i>	12
2.5	Considerações finais	12
3	Modelos deformáveis tradicionais	14
3.1	Considerações iniciais	14
3.2	Modelos deformáveis	14
3.3	Modelos deformáveis paramétricos	16
3.3.1	Formulação por minimização de energia	16
3.3.2	Formulação dinâmica de forças	21
3.4	Modelos deformáveis geométricos	22
3.4.1	Teoria da evolução da curva	23
3.4.2	Método do conjunto de níveis	24
3.4.3	Relação com os modelos deformáveis paramétricos	27

3.5	Extensões dos modelos deformáveis	27
3.6	Considerações finais	28
4	O fluxo do Vetor Gradiente (GVF)	29
4.1	Considerações iniciais	29
4.2	Força potencial gaussiana de multipla-escala	29
4.3	Força de pressão	30
4.4	Força potencial de distância	31
4.5	Força dinâmica de distância	32
4.6	Força interativa	32
4.7	Fluxo do vetor gradiente	34
4.7.1	Mapa de bordas	35
4.8	Considerações finais	37
5	O modelo RGVF (<i>Recursive Gradient Vector Flow</i>)	39
5.1	Considerações iniciais	39
5.2	A metodologia	39
5.3	O algoritmo RGVF	41
5.3.1	Inicialização de variáveis	41
5.3.2	Aquisição da imagem	42
5.3.3	Pré-processamento	43
5.3.4	Cálculo da força externa RGVF	44
5.3.5	Processo de deformação	45
5.3.6	Resultados	49
6	Resultados e conclusões	54
6.1	Considerações iniciais	54
6.2	Resultados da aplicação	54
6.3	Conclusões e principais apreciações	60
6.3.1	Trabalhos futuros	61
6.3.2	Perspectiva global	61
	Referências	61
A	Técnicas tradicionais de segmentação de imagens	68
A.1	Técnica de limiarização - <i>threshold</i>	69
A.1.1	Histograma	70

A.2	Técnica para detecção de bordas	71
A.2.1	Técnica de Sobel	71
A.2.2	Técnica de Laplace	73
A.2.3	Formação de contornos	74
A.3	Segmentação por região	75
A.3.1	Crescimento de região	76
A.3.2	Partição de região	77
A.3.3	Divisão e fusão de regiões	78
A.4	Segmentação por cor	78
B	Código fonte do modelo deformável RGVF	80

Introdução

1.1 Considerações iniciais

A partir do crescente desenvolvimento e aplicabilidade no diagnóstico e tratamento de doenças, as imagens médicas tornaram-se um importante recurso que está revolucionando a medicina. Com o aumento das necessidades médicas, foram desenvolvidas técnicas computacionais de apoio à análise e extração de informação. Das técnicas computacionais, espera-se precisão na representação de estruturas, facilidade na reprodução de testes e eficiência na extração de dados quantitativos que dêem suporte às pesquisas biomédicas e atividades clínicas. A procura destas características motivou o progresso da segmentação de imagens aplicada à área médica (Llapa-Rodríguez ; Gonzaga, 2003a). Ela é empregada em uma infinidade de situações como diagnóstico (Taylor, 1995), localização de patologias (Zijdenbos ; Dawant, 1994), tratamento (Khoo et al., 1997), correção parcial de dados na imagem (Muller-Gartner et al., 1992), e cirurgia assistida por computador (Ayache et al., 1996), (Grimson et al., 1997).

Em geral, as técnicas de segmentação são agrupadas em duas grandes categorias: a aproximação baseada em regiões e a baseada em bordas. A aproximação baseada em

regiões agrupa *pixels*¹ com propriedades semelhantes, geralmente fazendo uso de algoritmos de crescimento de regiões ou *split-and-merge*, para separar o fundo e o objeto de interesse na imagem. Por outro lado, a aproximação baseada em bordas aproveita a variação de *pixels* para o desenho inicial das bordas de interesse e finalmente é aplicada uma operação de enlace que as aprimora.

Figura 1.1: Variabilidade na qualidade das imagens, nas bordas e no ruído presente nas imagens médicas. A imagem esquerda apresenta uma angiografia da artéria carótida e a direita um ultra-som do abdômen.

A maioria dos sistemas médicos atuais das categorias referidas anteriormente baseiam-se na utilização de *thresholding*², que tenta distinguir o fundo e a estrutura de interesse através de estimativas feitas nos níveis de cinza da imagem (Gonzales ; Woods, 1992), (Jain et al., 1995), (Schalkoff, 1989). Outra técnica comumente utilizada é o delineamento manual. Esta estratégia permite segmentar manualmente seções de estruturas de interesse que não foram reconhecidas pelo sistema. Apesar dos resultados desta segmentação serem aceitáveis, o tempo gasto e o esforço empregado fazem dela inadequada. Além disso, os resultados ficam com uma forte dependência do tempo e do usuário que fez a segmentação. Por exemplo, numa mesma imagem poderiam ser identificadas diferentes bordas devido à mudança de especialista ou à variação do tempo investido na segmentação.

Embora esses métodos permitam uma melhora na atuação da segmentação de imagens, os resultados são freqüentemente insatisfatórios. Sua utilização evidenciou consideráveis limitações devido à variação na qualidade, nas bordas fracas e no ruído presente neste tipo de imagens (ver figura 1.1). Assim, observa-se a necessidade de desenvolver técnicas robustas que realizem um tratamento especializado.

¹O *pixel* ou *pel* são abreviações de *picture element*, que correspondem à menor unidade gráfica de uma imagem matricial.

²Maior informação desta técnica de limiarização, é apresentada no apêndice A.

Neste trabalho, apresenta-se uma sofisticada técnica de segmentação de bordas em imagens médicas. O modelo é chamado de contornos deformáveis por fluxo recursivo do vetor gradiente, o qual permite a utilização de conhecimento *a priori*, fortalecendo o tratamento de ruídos e falsas fronteiras; apresentando assim, características de precisão, reprodutibilidade nos testes e quantificação, as quais são necessárias para o desenvolvimento de pesquisas biomédicas e atividades clínicas.

1.2 Motivação

Gerenciar as variações na qualidade e no ruído originadas na formação de imagens, é o que se espera das técnicas de segmentação em imagens médicas (Llapa-Rodríguez ; Gonzaga, 2003b). Existem dois tipos de ruídos: o primeiro é o ruído aleatório causado pelos aparelhos, tipos de filmes e outros elementos que apóiam o exame. Esta degradação não só afeta a resolução perceptível, como também cria diferenças indesejáveis nos níveis de cinza. O segundo é o ruído sistemático relacionado à textura do objeto de interesse, o qual dependendo da técnica de segmentação empregada, poderia perturbar a segmentação ou ser utilizado como conhecimento *a priori*. Observa-se que utilizando maior quantidade de informação, é melhorada a precisão na segmentação de imagens. Neste aspecto, a aplicação das técnicas de contornos deformáveis, tiram vantagem com respeito às técnicas tradicionais, devido ao aproveitamento das características intrínsecas da imagem no seu processamento (Kass et al., 1988).

Desde sua introdução, os contornos deformáveis vêm se estabelecendo como um importante recurso para a solução de problemas em processamento de imagens, particularmente na segmentação de imagens e *tracking*. O termo contornos deformáveis ou *deformable contours* refere-se ao estado de equilíbrio que atinge uma curva inicial sujeita à deformação originada pela ação de forças internas (intrínsecas à geometria da curva) e forças externas (derivadas da própria imagem). As forças internas são projetadas para preservar a uniformidade do modelo durante a deformação, e as externas são definidas para direcionar o modelo aos contornos do objeto ou outras características desejadas dentro da imagem.

Uma dificuldade com esses métodos é a necessidade de uma boa estimativa inicial do contorno, o que reflete no resultado esperado (ver figura 1.2). Por outro lado, eles facilitam a incorporação de informações *a priori* (textura, tamanho, forma, etc.), bem como a interação com o usuário quando esta se torna necessária. Isto vem motivando a apli-

cação desses modelos em áreas diversas, assim como o desenvolvimento e crescimento acelerado de novos modelos.

Figura 1.2: A importância da localização do contorno inicial na aplicação dos modelos deformáveis tradicionais. Existe uma dependência direta da inicialização e a sua convergência.

Existem basicamente dois tipos de modelos deformáveis: modelos geométricos e paramétricos. Os modelos geométricos são baseados na teoria de evolução da curva (Sapiro ; Tannenbaum, 1993), (Kimia et al., 1995), (Kimmel et al., 1995), (Alvarez et al., 1993) e no método de conjunto de níveis (Osher ; Sethian, 1988), (Sethian, 1999). Eles representam as curvas ou superfícies de forma implícita como um conjunto de níveis de uma função escalar de alta dimensão. Os modelos paramétricos, por outro lado, representam curvas e superfícies explicitamente na sua forma paramétrica durante a deformação. Esta representação permite uma interação direta com o modelo, além de conduzir uma representação compacta e em tempo real.

No desenvolvimento deste trabalho, será dado um enfoque especial nos modelos paramétricos, que sintetizam as curvas paramétricas no domínio da imagem e as movem em direção às bordas desejadas. Existem duas principais dificuldades na implementação desses modelos. A primeira é a necessidade da curva de inicialização de envolver o contorno objetivo para assegurar um resultado satisfatório, e a segunda é a existência de proble-

mas no tratamento de regiões côncavas (Abrantes ; Marques, 1996), (Davatzikos ; Prince, 1995).

Com o desenvolvimento de uma nova força externa proposta por Xu e Prince (Xu ; Prince, 1997), (Xu ; Prince, 1998b) chamada de fluxo do vetor gradiente (GVF), conseguiu-se resolver ambos os problemas. Ela baseia-se na difusão do vetor gradiente derivado dos níveis de cinza da imagem. Mediante esta força, o campo resultante aumenta seu âmbito de captura, de forma que a curva inicial possa ser direcionada a partir de regiões mais afastadas do contorno objetivo. Para solução do segundo problema, a difusão do campo GVF aumenta a capacidade de orientação em regiões côncavas, onde os modelos tradicionais apresentam dificuldades.

Mesmo que os problemas tenham sido solucionados pelo modelo GVF, na prática, encontram-se dificuldades na variação de ruídos e no tratamento de falsas fronteiras. Isto origina a desorientação na deformação e a necessidade de um maior número de iterações para alcançar o objetivo desejado, quando este for possível.

1.3 Objetivos

O objetivo deste trabalho é desenvolver um novo campo *edge map* denominado de RGVF (*recursive gradient vector flow*), o qual permitirá fortalecer e agilizar a aplicação dos modelos deformáveis na análise de imagens médicas.

Este campo *edge map*, utilizado como força externa, será modificado através de cálculos recursivos, gerando um âmbito de captura sem perturbações, indistinto do ruído existente na imagem. O cálculo que permite aperfeiçoar o *edge map* será desenvolvido a partir da técnica de espaço de escalas utilizando o processo de difusão.

Este algoritmo incorporará, além da atividade de segmentação, a opção de classificação e reconhecimento de alvos, mediante a utilização de um valor mínimo de deformação. Com isto, será possível determinar a presença ou ausência de um objeto desejado.

1.4 Organização do trabalho

Este primeiro capítulo mostrou algumas considerações iniciais e o contexto no qual se insere este trabalho. O restante do texto está organizado da seguinte forma.

O capítulo 2 mostra uma visão das principais aplicações dos modelos deformáveis, o porquê da utilização dos mesmos na área médica e as principais vantagens que oferecem na análise de imagens geradas a partir de raios X, tomografias computadorizadas, angiografias, ressonância magnética e ultra-som.

O capítulo 3 introduz o conceito de modelos deformáveis. São apresentados os modelos paramétricos e geométricos, as formulações aplicadas em cada um deles e algumas propostas de extensão dos modelos.

O capítulo 4 apresenta a força externa fluxo do vetor gradiente (GVF), suas principais características e deficiências no tratamento de imagens, além de outras forças externas utilizadas na atualidade.

O capítulo 5 descreve o modelo RGVF (*recursive gradient vector flow*) no qual são apresentados detalhes do algoritmo, os procedimentos empregados, as modificações realizadas e alguns exemplos para testar e entender o seu funcionamento.

O capítulo 6 apresenta a aplicação do modelo RGVF na análise de imagens médicas e sintéticas para sua validação, além das conclusões e futuras aplicações do modelo.

Como ajuda para o esclarecimento de conceitos básicos no tratamento de imagens, foi desenvolvido o apêndice A, o qual apresenta as técnicas tradicionais de segmentação e o equacionamento que as sustenta. Finalmente é apresentado o apêndice B, no qual é oferecido o código fonte do algoritmo RGVF, motivo desta dissertação.

Modelos deformáveis na análise de imagens médicas

2.1 Considerações iniciais

Embora os modelos deformáveis tenham sido originalmente desenvolvidos para aplicações em visão computacional (*motion tracking*) e computação gráfica (*segmentation e shape modeling*), seu potencial para a análise de imagens médicas começou a se concretizar com o aparecimento de interessantes resultados nesta área. Eles têm sido aplicados em imagens geradas a partir de raios X, tomografias computadorizadas, angiografias, ressonância magnética e ultra-som.

Os modelos deformáveis 2D (contornos deformáveis) assim como os 3D (superfícies deformáveis) têm sido usados na segmentação, visualização, *track*, e quantização de estruturas anatômicas (McInerney ; Terzopoulos, 1996). São aplicados por exemplo, na análise do cérebro, coração, face, artérias coronárias e da retina, rins, pulmão, estômago, fígado, esqueleto, vértebras; em objetos como tumores, fetos; e estruturas celulares como neurônios e cromossomas.

Neste capítulo serão apresentadas aplicações dos modelos deformáveis na segmentação de imagens médicas incluindo a segmentação, *matching* e *motion tracking*. Finalmente serão expostas algumas considerações do presente capítulo.

2.2 Modelos deformáveis na segmentação de imagens

Segmentar uma imagem de interesse em um subconjunto de estruturas é uma etapa importante na análise de imagens médicas para uma compacta representação analítica das formas. Atualmente na área médica existem tarefas de segmentação que são realizadas de forma manual, o que motiva resultados dependentes das habilidades do operador. Isso dificulta a análise de imagens, não sendo factível comparações e acompanhamento de doenças.

A aplicação de técnicas tradicionais de segmentação em baixo nível como crescimento de regiões, detecção de bordas e *threshold*, requerem também uma considerável atuação do especialista (ver apêndice A). Além disso, automatizar este tipo de segmentações são difíceis, devido à variação e complexidade de cada caso.

Um método baseado em modelos deformáveis pode muitas vezes reduzir as limitações das técnicas manuais e de processamento tradicional de imagens, oferecendo características de suavidade ¹ e continuidade ² nos modelos no tratamento de ruído, rupturas e outras irregularidades nas bordas. Com estas propriedades, esta técnica fica robusta e elegante para unir descontinuidades e tratar o ruído, na procura de uma coerente e consistente estrutura objetivo (ver figura 2.1).

Uma das principais aplicações dos modelos deformáveis é a segmentação de estruturas 2D, mas apresenta limitações devido à necessidade de interação. Normalmente o usuário precisa inicializar o modelo deformável perto do objeto de interesse, gerando assim uma deformação localizada (ver figura 2.2). Uma outra limitação é o cálculo das energias utilizadas nos modelos, que podem limitar a flexibilidade geométrica além da incapacidade de transformações topológicas. Diversos métodos têm sido propostos para favorecer a segmentação automática dos contornos deformáveis. O modelo balão desenvolvido por (Cohen ; Cohen, 1993) é um exemplo deles, o qual utiliza uma força de pressão para ex-

¹Por suavidade entende-se a característica pela qual a curva de definição das bordas apresenta mudanças ordenadas e metódicas.

²A continuidade refere-se à condição de obter um percurso fechado que conforme as bordas de interesse, através de algum método de interpolação de pontos.

Figura 2.1: O tratamento de ruído na segmentação de imagens médicas (ultra-som cardíaco do ventrículo esquerdo) utilizando modelos deformáveis.

pandir ou reduzir o modelo em direção às bordas de interesse, eliminando os problemas de inicialização.

Figura 2.2: A utilização dos contornos deformáveis numa (a) tomografia computadorizada do ventrículo esquerdo. (b) A imagem depois da aplicação do detector de bordas. (c) A inicialização do contorno deformável. (d)-(f) A procura da minimização de energia nas bordas do ventrículo esquerdo.

Uma outra aplicação é observada na segmentação de imagens 3D, oferecendo rapidez e robustez nos resultados (ver figura 2.3). Estes modelos deformáveis, chamados também de superfícies deformáveis, foram utilizados pela primeira vez em visão computacional por (Terzopoulos ; Fleischer, 1988). Diversas aplicações na segmentação de estruturas em imagens 3D existem na atualidade. O trabalho inicial foi realizado por (Miller et al., 1991) que construiu uma esfera que geometricamente é deformada até se ajustar ao objeto 3D extraído de uma tomografia computadorizada 3D. Com base neste trabalho foram realizadas diversas pesquisas, que utilizaram conceitos de elementos finitos, técnicas físicas, parametrizações de Fourier, etc.

Figura 2.3: O modelo deformável **Balão** utilizado na procura das bordas do ventrículo esquerdo.

2.2.1 Incorporação de conhecimento *a priori*

Em imagens médicas geralmente é conhecida a localização e orientação de objetos de interesse, e este conhecimento pode ser incluído nos modelos deformáveis como: condições iniciais, dados de restrição, parâmetros de forma e procedimentos de ajuste.

Neste caso, utilizar o conhecimento anatômico é importante para gerar um método que não só descreva o tamanho, forma, localização e orientação do objeto de interesse, mas também, que permita utilizar variações nestas características para uma robusta interpretação de imagens médicas. Muitos pesquisadores têm incorporado conhecimento de formato nos modelos. Eles usualmente utilizam '*hand-crafted*' para trabalhar com formas previstas ou variações. Outros processam o ajuste dos modelos deformáveis no âmbito probabilístico (Worring et al., 1993), (Vemuri ; Radisavljevic, 1994) e inserem conhecimento *a priori* da estrutura dos objetos.

2.3 Matching

Matching em imagens faz parte da aplicação de métodos para representar e etiquetar regiões. A extração e rotulagem de estruturas anatômicas no cérebro a partir de imagens de ressonância magnética, é um exemplo de *matching* utilizando modelos deformáveis e conhecimento *a priori*. O conhecimento anatômico é feito explícito na forma de um atlas 3D do cérebro. O atlas é modelado como um objeto físico onde são dadas propriedades elásticas. Depois em um alinhamento global, o atlas é deformado e ajustado nas correspondentes regiões do volume do cérebro, respondendo às forças derivadas das características da imagem (ver figura 2.4). Como hipótese é utilizada a informação de "todo cérebro ter a mesma estrutura topológica", tendo diferenças só em detalhes de forma. A idéia de utilizar o atlas como um objeto elástico foi inicialmente proposta por (Broit, 1981).

Figura 2.4: O resultado de aplicar *Matching* e rotulagem de estruturas, a partir do atlas deformável utilizando imagens por ressonância magnética do cérebro.

A técnica do atlas deformável tem diversos problemas como sua sensibilidade ao local de inicialização, que pode levá-lo a uma pobre atuação. Um outro problema é observado no tratamento de características de interesse, quando estas ficam muito próximas umas

com outras, as quais podem causar problemas no *matching* e o atlas se deformar de maneira incorreta.

2.4 Motion tracking

A idéia de utilizar modelos deformáveis em *tracking* foi originalmente proposto na área de visão computacional por (Kass et al., 1988) e (Terzopoulos ; Fleischer, 1988) para rastrear o movimento de estruturas microscópicas e macroscópicas.

Não obstante, sua principal aplicação encontra-se na medição do comportamento dinâmico do coração humano (ver figura 2.5), especialmente do ventrículo esquerdo, permitindo a realização de estudos de movimento nas paredes do coração para determinar a gravidade de doenças como a isquemia.

Atualmente, a ressonância magnética e outras tecnologias fornecem já imagens 3D com uma excelente resolução espacial e temporal, para as quais, os modelos deformáveis estão sendo adequados para oferecer ótimos resultados.

2.5 Considerações finais

Neste capítulo examinou-se o rápido desenvolvimento das aplicações dos modelos deformáveis na análise de imagens médicas. Observou-se o porque da utilização destes modelos e quais são as vantagens que oferecem frente a técnicas tradicionais de segmentação.

Apresentou-se diversas características que são importantes nos modelos como a informação *a priori* e os pontos relevantes que permitem um tratamento especializado para a análise de imagens médicas.

Mencionou-se também, algumas deficiências e novas necessidades que precisam ser atingidas nesta área, e que são chaves para a direção de futuras pesquisas.

Figura 2.5: Tracking do movimento do ventrículo esquerdo durante um ciclo cardíaco (1-16), utilizando a força balão como modelo deformável.

Modelos deformáveis tradicionais

3.1 Considerações iniciais

Neste capítulo serão descritos os modelos deformáveis como resultado de uma conjunção de forças que procuram sua estabilidade na fronteira ou alguma outra característica relevante na imagem. Serão apresentados os conceitos de modelos deformáveis paramétricos, geométricos, a teoria que dá suporte a eles e algumas propostas de extensão dos modelos.

3.2 Modelos deformáveis

Os modelos deformáveis são curvas ou superfícies definidas no domínio espacial da imagem que se movimentam sob a influência de forças internas vindas do próprio modelo deformável, e forças externas calculadas das características da imagem (ver figura 3.1). A definição dessas forças é feita de forma que o modelo procure as fronteiras do objeto ou algum outro atributo desejado na imagem. Os modelos deformáveis são amplamente utilizados em aplicações como detecção de bordas (Kass et al., 1988), (Cohen ; Cohen, 1993), modelagem de formas (Terzopoulos ; Fleischer, 1988), (McInerney ; Terzopoulos

los, 1995), segmentação (Leymarie ; Levine, 1993), (Durikovic et al., 1995), e *motion tracking* (Terzopoulos ; Szeliski, 1992), (Leymarie ; Levine, 1993).

Figura 3.1: O comportamento das forças internas e externas nos modelos deformáveis. Uma curva paramétrica é inicializada no domínio da imagem de interesse, e é deformada pela ação da energia interna (forças geradas na própria curva) e da energia externa (forças derivadas da imagem).

Na literatura atual existem dois tipos gerais de modelos deformáveis: os modelos deformáveis paramétricos (Kass et al., 1988), (Cohen, 1991), (Terzopoulos ; Fleischer, 1988), (McInerney ; Terzopoulos, 1995) e os modelos deformáveis geométricos (Caselles et al., 1993), (Malladi et al., 1995), (Caselles et al., 1997).

Os modelos deformáveis paramétricos, durante a deformação, representam curvas ou superfícies explicitamente na sua forma paramétrica. Esta representação permite uma interação direta com o modelo e uma compacta representação para rápidas implementações. A adaptação topológica, durante a deformação, pode ser difícil.

Os modelos deformáveis geométricos, por outro lado, tratam as mudanças topológicas com naturalidade. Estes modelos baseiam-se na teoria da evolução da curva (Sapiro ; Tannenbaum, 1993), (Kimia et al., 1995), (Kimmel et al., 1995), (Alvarez et al., 1993) e no método do conjunto de níveis (Osher ; Sethian, 1988), (Sethian, 1999). Eles representam curvas e superfícies de forma implícita como um conjunto de níveis de uma função escalar n -dimensional. A parametrização é calculada só depois de completar a deformação, pela qual, este modelo oferece uma fácil adaptação topológica. Apesar dessas diferenças fundamentais, os princípios de ambos os métodos são muito similares.

O diagrama da figura 3.2 apresenta uma visão geral dos principais modelos de forças desenvolvidos nos modelos paramétricos e geométricos.

Figura 3.2: O desenvolvimento das pesquisas em modelos deformáveis a partir dos modelos paramétricos e geométricos.

3.3 Modelos deformáveis paramétricos

Dentro dos modelos deformáveis paramétricos serão apresentados dois tipos de formulações:

- A formulação por minimização de energia.
- A formulação dinâmica de forças.

Embora estas duas formulações permitam resultados similares, a primeira procura satisfazer princípios de minimização nas suas soluções, enquanto que a segunda oferece flexibilidade na utilização de tipos mais gerais de forças de deformação (forças externas).

3.3.1 Formulação por minimização de energia

A formulação por minimização de energia nos contornos deformáveis procura encontrar uma curva paramétrica que minimize a soma das energias interna e potencial ou externa.

A energia interna é definida na própria curva, determina a tensão ou suavidade das bordas. A energia potencial é definida sobre o domínio da imagem, permite encontrar o mínimo local nas fronteiras do objeto.

Em termos matemáticos um contorno deformável é uma curva $X(s) = (x(s), y(s))$, $s \in [0, 1]$, a qual se movimenta através do domínio espacial da imagem para minimizar a energia funcional conforme a equação 3.1.

$$E(X) = S(X) + P(X) \quad (3.1)$$

O primeiro termo corresponde à **energia interna**, a qual é definida como:

$$S(X) = \frac{1}{2} \int_0^1 \alpha |X'(s)|^2 + \beta |X''(s)|^2 ds \quad (3.2)$$

A derivada de primeira ordem faz com que o modelo seja facilmente deformável (ver figura 3.3) e a de segunda ordem evita fortes variações (ver figura 3.4). Com estes termos a energia interna manterá uma deformação vigiada e com suaves variações.

Figura 3.3: O comportamento elástico que forma parte da energia interna do modelo deformável.

Os parâmetros de peso α e β são usados para controlar o grau de elasticidade e rigidez no modelo. Na prática, freqüentemente α e β são determinados como constantes.

Figura 3.4: O comportamento rígido que forma parte da energia interna do modelo deformável.

O segundo termo da energia funcional, dada na equação 3.1 é a **energia potencial**. Ela também é chamada de energia externa, é calculada pela integral de $P(x, y)$ no contorno $X(s)$:

$$P(X) = \int_0^1 P(X(s)) ds \quad (3.3)$$

A função da energia potencial $P(x, y)$ é obtida a partir das características da imagem (ver figura 3.5). Foi definida para assumir valores altos nas fronteiras do objeto. Ela também pode ser utilizada na procura de outras características na imagem.

Dada uma imagem em níveis de cinza $I(x, y)$ vista como uma função de variáveis de posição contínua (x, y) , uma típica função de energia potencial é mostrada na equação 3.4.

$$P(x, y) = -|\nabla(G_\sigma(x, y) * I(x, y))|^2 \quad (3.4)$$

Em que:

- $G_\sigma(x, y)$ é uma função Gaussiana bi-dimensional com desvio padrão σ .
- ∇ é o operador gradiente.
- $*$ é o operador de convolução 2D.

Figura 3.5: A energia potencial ou energia externa $P(x, y)$, gerada a partir das bordas de uma imagem por ressonância magnética.

Se os atributos desejados em uma imagem são linhas, então a função de energia potencial apropriada pode ser definida da seguinte forma:

$$P(x, y) = G_{\sigma}(x, y) * I(x, y) \quad (3.5)$$

Na energia potencial, tanto na procura de fronteiras como de linhas, o incremento de σ amplia o âmbito de atração. Entretanto, um grande σ pode também causar um deslocamento das fronteiras do objeto, gerando assim resultados menos exatos.

Desprezando a seleção de uma correta função de energia potencial, a aplicação da formulação por minimização de energia é sempre a mesma. Encontrar uma curva $X(s)$ que minimize a energia funcional $E(X)$ é conhecida como o problema de variação (Courant ; Hilbert, 1953), o qual mostra que a curva que minimiza $E(X)$ deve satisfazer à seguinte equação de Euler-Lagrange:

$$\alpha X''(s) - \beta X''''(s) - \nabla P(X) = 0 \quad (3.6)$$

Para um melhor entendimento do comportamento físico dos contornos deformáveis, pode-se expressar a equação 3.6 como uma equação de força de equilíbrio,

$$F_{int}(X) + F_{pot}(X) = 0 \quad (3.7)$$

em que a força interna é dada por

$$F_{int}(X) = \alpha X''(s) - \beta X''''(s) \quad (3.8)$$

e a força potencial é representada por

$$F_{pot}(X) = -\nabla P(X) \quad (3.9)$$

A força interna F_{int} é a responsável por manter a elasticidade e a curvatura do modelo, ao mesmo tempo que, a força potencial F_{pot} exerce uma força em direção às fronteiras desejadas.

Para encontrar uma solução para a equação 3.6, o contorno deformável é feito dinâmico para tratar $X(s)$ em função do tempo t assim como de s , o que resulta em $X(s, t)$. Assim, a derivada parcial de X com respeito a t será aplicada na equação 3.6 como pode ser observado na igualdade:

$$X_t(s, t) = \alpha X''(s, t) - \beta X''''(s, t) - \nabla P(X) \quad (3.10)$$

Quando a solução $X(s, t)$ fica estável, o termo $X_t(s, t)$ desaparece e assim chega-se à solução da equação 3.6.

3.3.2 Formulação dinâmica de forças

Na seção anterior, o modelo deformável foi modelado como um problema estático, e uma variável t foi inserida para minimizar a energia. Às vezes é conveniente utilizar uma formulação de forças, para modelos deformáveis, que diretamente se desenvolva a partir de um determinado problema dinâmico. Tal formulação permite o uso de tipos mais gerais de forças externas e que não são mais forças potenciais.

Conforme a segunda lei de Newton, as dinâmicas de um contorno $X(s, t)$ devem satisfazer:

$$X_t''(s, t) = F_{damp}(X) + F_{int}(X) + F_{ext}(X) \quad (3.11)$$

Em que:

- F_{damp} é a força de amortecimento definida como $-\gamma X_t(s, t)$, sendo γ o coeficiente de amortecimento.

Da equação 3.11 e utilizando a definição da força F_{damp} pode-se encontrar a seguinte dinâmica do contorno deformável:

$$\gamma X_t(s, t) = F_{int}(X) + F_{ext}(X) \quad (3.12)$$

As forças internas são as mesmas conforme a equação 3.8, e as externas podem ser forças potenciais ou não potenciais. Elas são freqüentemente definidas como a sobreposição de tipos variados de forças:

$$F_{ext}(X) = F_1(X) + F_2(X) + \dots + F_N(X) \quad (3.13)$$

Onde o número total de forças externas está representado por N . Este tipo de formulação oferece um maior número de termos de controle que facilitam a administração do comportamento das forças externas.

3.4 Modelos deformáveis geométricos

Os modelos deformáveis geométricos, propostos de forma independente por (Caselles et al., 1993) e (Malladi et al., 1995), fornecem uma refinada solução para direcionar as limitações dos modelos deformáveis paramétricos. Estes modelos têm como base a teoria da evolução da curva (Sapiro ; Tannenbaum, 1993), (Kimia et al., 1995), (Kimmel et al., 1995), (Alvarez et al., 1993) e o método de conjunto de níveis (Osher ; Sethian, 1988), (Sethian, 1999).

As curvas e superfícies são geradas usando simples medidas geométricas, resultando em uma evolução independente da parametrização. Desde que a evolução da deformação é independente da parametrização, as curvas ou superfícies podem ser representadas, de forma implícita como uma função de conjunto de níveis n -dimensionais, resultando em mudanças topológicas que podem ser tratadas de forma automática. A utilização desta vantagem pode ser observada na figura 3.6.

Figura 3.6: A utilização dos modelos deformáveis geométricos em imagens médicas, através de mudanças topológicas.

3.4.1 Teoria da evolução da curva

A finalidade da teoria da evolução da curva é a deformação das curvas usando simples medidas geométricas como a normal e a curvatura, em contraposição à utilização de dados que possam ser derivados de uma curva paramétrica qualquer.

Considerando a curva em movimento $\mathbf{X}(s, t) = [X(s, t), Y(s, t)]$, onde s é uma parametrização qualquer e t é o tempo, ademais, é denotada a unidade normal como N e a curvatura como κ , a evolução da curva através da normal pode ser caracterizada pela seguinte equação diferencial parcial:

$$\frac{\partial \mathbf{X}}{\partial t} = V(\kappa)N \quad (3.14)$$

Onde:

- $V(\kappa)$ é chamada de função *speed*, utilizada para determinar a rapidez da evolução da curva.

Percebe-se que a curva em movimento numa direção arbitrária pode ser sempre reparametrizada, tendo a mesma forma da equação 3.14 (Kimia, 1990). O fato de ter uma deformação tangente, atinge unicamente a parametrização da curva, mas não a sua forma e geometria.

Estudos mais detalhados da deformação na teoria da evolução da curva são os chamados *curvature deformation* e *constant deformation*. A *curvature deformation* é dada pela equação

$$\frac{\partial \mathbf{X}}{\partial t} = \alpha \kappa N \quad (3.15)$$

Onde α é uma constante positiva. Esta equação permite alisar a curva e eventualmente reduzi-la para um ponto circular (Grayson, 1989). A utilização da *curvature deformation* tem um efeito similar ao uso da força interna elástica dos modelos deformáveis paramétricos.

A *constant deformation* é dada por:

$$\frac{\partial \mathbf{X}}{\partial t} = V_0 N \quad (3.16)$$

Na qual, V_0 é o coeficiente que determina a velocidade e direção da deformação. A *constant deformation* tem um efeito similar à força de pressão dos modelos deformáveis paramétricos (ver no capítulo 4).

3.4.2 Método do conjunto de níveis

O método do conjunto de níveis é o responsável pela adaptação topológica automática e por fornecer as bases do esquema numérico usado nos modelos deformáveis geométricos (Osher ; Sethian, 1988), (Sethian, 1985), (Sethian, 1989).

No método do conjunto de níveis, a curva é representada de forma implícita como um conjunto de níveis de uma função escalar 2D que é definida sobre o domínio espacial da imagem. O conjunto de níveis é definido como grupo de pontos que tem a mesma função valor. A figura 3.7 mostra uma curva que exemplifica o grupo de pontos que formam o conjunto de nível zero.

Figura 3.7: Uma curva como o conjunto de níveis. Da esquerda para a direita temos uma simples curva, a representação da função de conjunto de níveis onde o nível zero fica na região mais escura, e o mapa de altura do conjunto de níveis respectivamente.

O objetivo da função do conjunto de níveis é fornecer uma representação implícita da evolução da curva. Este método permite a evolução da curva mediante a atualização da função de conjunto de níveis em coordenadas fixas através do tempo. Ela fica válida só até que a curva possa mudar sua topologia. Esta situação é observada na figura 3.8.

Dada uma função de conjunto de níveis $\phi(x, y, t)$ com um contorno $\mathbf{X}(s, t)$, no seu conjunto de níveis zero tem-se o seguinte:

$$\phi[\mathbf{X}(s, t), t] = 0 \quad (3.17)$$

Figura 3.8: O conjunto de nível zero divide-se em 2 curvas. Nesse momento a função de conjunto de níveis não é mais válida devido à mudança topológica que foi realizada.

Derivando-se a equação 3.17 com respeito a t e utilizando-se a regra da cadeia, obtém-se:

$$\frac{\partial \phi}{\partial t} + \nabla \phi \cdot \frac{\partial \mathbf{X}}{\partial t} = 0 \quad (3.18)$$

Onde $\nabla \phi$ denota o gradiente de ϕ e assumindo-se que ϕ é negativo dentro do conjunto de nível zero e positivo fora dele, a normal para a curva de conjunto de nível é dada por

$$N = -\frac{\nabla \phi}{|\nabla \phi|} \quad (3.19)$$

Utilizando este fato e a equação 3.14, pode-se reescrever a equação 3.18 da seguinte forma

$$\frac{\partial \phi}{\partial t} = V(\kappa) |\nabla \phi| \quad (3.20)$$

Onde a curvatura κ no conjunto de nível zero é dada por:

$$\kappa = \nabla \cdot \frac{\nabla \phi}{|\nabla \phi|} = \frac{\phi_{xx}\phi_y^2 - 2\phi_x\phi_y\phi_{xy} + \phi_{yy}\phi_x^2}{(\phi_x^2 + \phi_y^2)^{3/2}} \quad (3.21)$$

A relação entre a equação 3.14 e a equação 3.20 prevê os fundamentos para o desempenho da evolução da curva usando o método do conjunto de níveis.

Três assuntos precisam ser considerados para implementar os contornos deformáveis geométricos:

1. Uma função inicial $\phi(x, y, t = 0)$ deve ser montada de forma que para o conjunto de nível zero seja correspondida a posição inicial do contorno. É comum observar a igualdade $\phi(x, y, 0) = D(x, y)$, onde $D(x, y)$ é a distância de cada ponto do espaço de referência ao conjunto de nível zero.

Sethian e Malladi (1999), desenvolveram um método chamado de marcha rápida, que pode construir a função de distância na ordem de $O(N \log N)$, onde N é o número de *pixels*. No entanto, podem aparecer algumas situações onde a distância pode ser calculada de um modo mais eficaz, por exemplo, quando o conjunto de nível zero pode ser descrito mediante a coleção de discos unidos que formariam a fronteira externa. Neste caso, a função da distância é calculada em $O(N)$ dada por

$$D(x) = \min_{i=1,2,\dots,M} (|x - c_i| - r_i)$$

Em que:

- $x = (x, y)$.
 - M é o número inicial de discos.
 - c_i e r_i são o centro e o raio de cada disco respectivamente.
2. Desde que a equação de evolução 3.20 seja derivada para o conjunto de nível zero, a função *speed* $V(\kappa)$ não é definida para mais um outro conjunto de níveis. Portanto, necessita-se um método que permita estender a função *speed* $V(\kappa)$ para todos os outros conjuntos de níveis. Muitas aproximações para aquelas extensões têm sido desenvolvidas. No entanto, a função do conjunto de níveis que se desenvolve utilizando estas funções *speed* estendidas podem perder propriedades de função de distância, causando imprecisões no cálculo da normal e da curvatura.
- Como resultado, a reinicialização da função de conjunto de níveis para a função de distância é freqüentemente requerida para estes métodos. Recentemente um método que não apresenta este problema foi proposto por (Adalsteinsson ; Sethian, 1999). Este método molda o problema da extensão *speed* a um problema de cálculo de fronteira, o qual pode então ser resolvido utilizando o método de marcha rápida.
3. Em aplicações de contornos geométricos, a constante de deformação é usada freqüentemente para deformações a grande escala, como concavidades, e protuberâncias. No entanto, pode causar formações rígidas nos cantos a partir de um conjunto uniforme inicial de nível zero. Uma vez que os cantos foram gerados, não resulta

clara a especificação sobre como continuaria a deformação. Um caminho natural seria a utilização da *entropy condition* originalmente proposta na área de análise da propagação por (Sethian, 1982).

3.4.3 Relação com os modelos deformáveis paramétricos

Esta relação pode ser formulada com maior precisão através da formulação por minimização de energia. (Caselles et al., 1997) mostrou que o contorno deformável geométrico é equivalente ao contorno deformável paramétrico sem o termo de rigidez. Assim, esta derivação permite utilizar a *speed function* induzida por uma força potencial, uma propriedade comum em quase todos os modelos deformáveis geométricos.

3.5 Extensões dos modelos deformáveis

Muitas extensões dos modelos deformáveis têm sido propostas, as quais direcionam duas importantes áreas de aproveitamento dos modelos deformáveis padrões.

A primeira área é referida à incorporação de conhecimento *a priori*. Sua utilização permite robustez e precisão nos resultados. A incorporação deste conhecimento requer treinamento que envolve muita interação manual para a cumular informação. Ela é usada para restringir deformações dos contornos ou superfícies e na extração de formas consistentes com os dados do treino.

A segunda área é referida à modelagem global das propriedades da forma. Os tradicionais modelos paramétricos e geométricos são modelos locais, isto é, são pensados para ser localmente estáveis. Propriedades globais como orientação e tamanho não são explicitamente modeladas. A modelagem das propriedades globais podem determinar maior robustez à inicialização, além disso, são importantes em reconhecimento de objetos e aplicações de interpretação de imagens, pois podem ser caracterizadas usando poucos parâmetros.

Embora o conhecimento *a priori* e as propriedades globais da forma são conceitos distintos, freqüentemente eles são utilizados de maneira conjunta. Observou-se também que as propriedades globais tendem a ser muito mais estáveis que as locais, por consequência, se a informação sobre propriedade globais é um conhecimento *a priori*, este poderia ser usado para melhorar o desempenho do modelo deformável.

Dentro dos modelos deformáveis que utilizam conhecimento *a priori* e/ou propriedades globais da figura pode-se mencionar os seguintes:

- O modelo deformável de Fourier (Staib ; Duncan, 1992), o qual utiliza a representação de Fourier para parametrizar os contornos e superfícies deformáveis.
- Modelo deformável usando análise modal ((Pentland ; Horowitz, 1991) (Nastar ; Ayache, 1996)), é um outro caminho para limitar os usuais movimentos não estruturados associados ao modelo deformável padrão.
- Modelo chamado *deformable superquadric*, proposto por (Terzopoulos ; Metaxas, 1991). Permite incorporar características locais e globais.
- Modelo de forma ativa (ASM) proposto por (Cootes et al., 1994) e (Cootes et al., 1995). Utiliza uma aproximação diferente para incorporar informação de forma. Eles não são obtidos mediante parametrização, senão através de um conjunto de pontos definidos nas características da imagem.

3.6 Considerações finais

Neste capítulo foram mostrados dois tipos gerais de modelos deformáveis, assim como as definições que permitem dar sustento e existência deles. Para o presente trabalho, nosso interesse fica restrito ao modelo deformável paramétrico utilizando a formulação por minimização de energia.

A equação de Euler permite encontrar uma curva que minimize a energia funcional $E(x)$. Porém, desde que esta energia funcional $E(x)$ seja não-convexa, a equação de Euler terá muitas soluções em mínimos locais. Mesmo que o mínimo global possa ser encontrado através de técnicas de otimização, geralmente o custo computacional é alto.

No presente trabalho será utilizado o método do gradiente descendente para encontrar a minimização desejada, mas como consequência, será requerida uma boa inicialização do modelo.

O fluxo do Vetor Gradiente (GVF)

4.1 Considerações iniciais

Este capítulo oferece uma visão geral dos diferentes tipos de forças externas utilizadas nos modelos deformáveis. Serão descritas as principais vantagens, deficiências e melhoras que foram realizadas acima de cada proposta.

A força denominada fluxo do vetor gradiente (GVF) será o centro desta discussão. Este método utiliza um campo de vetores denso na procura de minimizar uma certa energia funcional. A minimização é obtida através da solução de duas equações diferenciais parciais lineares, as quais difundem os vetores gradiente do *edge map* da imagem.

4.2 Força potencial gaussiana de multipla-escala

Pode-se observar uma utilização básica desta força nas equações (3.4) e (3.5) da seção 3.3.1, nas quais, o σ utiliza valores baixos para seguir as bordas do objeto com exatidão. Mas com este parâmetro diminuído, esta força só consegue atrair o modelo quando o *template* é inicializado muito próximo às fronteiras desejadas. Para remediar este problema,

(Kass et al., 1988) e (Terzopoulos et al., 1988) propuseram a força potencial Gaussiana aplicada em diferentes escalas para ampliar o âmbito de atração, mantendo as fronteiras do modelo sem distorções. A idéia básica é utilizar no começo um alto valor em σ para gerar uma função de energia potencial com um amplo vale ao redor da fronteira. Esta grosseira escala de força potencial Gaussiana permite atrair os contornos ou superfícies deformáveis às fronteiras desejadas a partir de âmbitos muito distantes. Quando os contornos ou superfícies conseguem alcançar o equilíbrio, o valor em σ é reduzido para permitir o acompanhamento das bordas em uma escala mais refinada. Este esquema efetivamente aumenta o âmbito de atração da força potencial Gaussiana. O defeito desta aproximação, no entanto, é a não existência de um teorema para estabelecer as mudanças praticadas em σ .

4.3 Força de pressão

Cohen (1991) sugeriu incrementar o âmbito de atração do modelo, utilizando a força de pressão e a força potencial Gaussiana. A força de pressão tem a vantagem de expandir ou reduzir a curva de deformação na procura das bordas desejadas, eliminando assim a necessidade da inicialização próxima. O uso deste modelo, conhecido como 'balão' (Cohen, 1991), pode ser observado na figura 4.1.

Figura 4.1: A convergência do modelo deformável utilizando a força de pressão na procura das fronteiras objetivo, inicializando a deformação (a) no interior do objeto e (b) encerrando a borda objetivo.

A força de pressão é definida como:

$$F_p(X) = w_p N(X) \quad (4.1)$$

Em que:

- $N(X)$ é a normal do modelo no ponto X .
- w_p é um parâmetro de intensidade.

O sinal em w_p vai depender do comportamento que o usuário espera do modelo (expansão ou redução). Tipicamente é escolhido pelo usuário.

Recentemente, para definir w_p , está sendo aproveitada a informação da região, para saber se o modelo está dentro ou fora do objeto desejado. O parâmetro de intensidade da força de pressão w_p é cuidadosamente selecionado de modo que esta força seja levemente inferior do que a força potencial Gaussiana das fronteiras significantes, mas o suficientemente grande para passar sobre falsas fronteiras. Quando começa a deformação do modelo, a força de pressão sustenta a expansão ou a redução do modelo até ele parar devido à força potencial Gaussiana. Uma desvantagem da utilização desta força é a possibilidade de fazer o modelo entrar em um *loop* infinito.

4.4 Força potencial de distância

Outra aproximação para aumentar o âmbito de atração é a função de energia potencial utilizando um mapa de distâncias como foi proposto por (Cohen ; Cohen, 1993). O valor do mapa de distâncias, em cada pixel, é obtido calculando a distância entre o pixel e o ponto mais próximo da fronteira, utilizando-se a distância Euclidiana (Danielsson, 1980) ou a distância de Chamfer (Borgefors, 1984).

Dado um mapa de distâncias $d(x, y)$, uma forma de definir a correspondente energia potencial (Cohen ; Cohen, 1993) é:

$$P_d(x, y) = -w_d \exp[-d(x, y)^2] \quad (4.2)$$

O correspondente campo de força potencial é dado por $-\nabla P_d(x, y)$.

4.5 Força dinâmica de distância

É uma outra proposta de força externa similar à força potencial de distância, mas não possui problemas de fronteiras em concavidades (Delingette, 1994), (MacDonald et al., 1994). Esta aproximação deriva a força externa via cálculo de distâncias em cada ponto que compõe o contorno ou superfície deformável. A distância é calculada mediante a determinação dos pontos que contornam as fronteiras ou outras características da imagem que estão em direção normal ao modelo. Este valor de distâncias é recalculado cada vez que o modelo é deformado. Vários critérios podem ser usados para definir os pontos da fronteira a serem examinados. O mais comum utiliza os *pixels* com magnitudes de intensidades elevadas ou pontos de borda gerados por algum detector de bordas.

Um *threshold* é especificado para o exame de distância máxima, evitando o uso de pontos não relevantes, e assim reduzir o tempo computacional. Esta força resultante, chamada de força dinâmica de distância, permite atrair os modelos deformáveis às características desejadas através de um âmbito somente limitado pelo *threshold* escolhido.

Dado um ponto X em um contorno ou superfície, sua unidade normal $N(X)$, o cálculo de distância $D(X)$, e um *threshold* de distância D_{max} , uma definição típica para a força dinâmica de distância é

$$F_D(X) = w_D \frac{D(X)}{D_{max}} N(X) \quad (4.3)$$

A desvantagem deste método é o tempo consumido na procura dos pontos em direção normal ao modelo em cada deformação. Utilizando um *threshold* de distância reduzido o tempo consumido diminui, mas produz um efeito indesejado de redução no âmbito de atração.

4.6 Força interativa

Em muitas circunstâncias é importante deixar o usuário atuar diretamente na deformação do modelo deformável. Esta interação, melhora a exatidão na segmentação quando a força externa não consegue encontrar as características desejadas numa imagem, por exemplo, se o usuário gostaria de puxar o modelo sobre determinadas características, ou influenciar o modelo com determinados pontos de referência identificados por um especialista, como é apresentado na figura 4.2. Esta característica dos modelos deformáveis

de permitir ao usuário interagir com o modelo pode ser facilmente modelada utilizando termos adicionais de força.

Figura 4.2: A aplicação da força interativa numa (a) tomografia computadorizada. Em (b) observa-se que a deformação do modelo é influenciada pelos gradientes e pontos de referência identificados pelo especialista.

Dois tipos de forças interativas frequentemente usadas são a força *spring* e a força *volcano* propostas por (Kass et al., 1988). A força *spring* é proporcional à distância entre um ponto X no modelo e um ponto p especificado pelo usuário:

$$F_s = w_s(p - X) \quad (4.4)$$

A força *spring* atua atraindo o modelo para p . O ponto X no modelo é selecionado por ser o ponto mais próximo a p , e é encontrado mediante heurísticas ao redor do local da vizinhança de p .

A força *volcano* é projetada para impulsionar o modelo longe da região ao redor do ponto p . Para a eficiência computacional do algoritmo, a força é estimada somente na vizinhança $N(p)$ como mostrado na equação 4.5,

$$F_v(X) = \begin{cases} w_v \frac{r}{|r|^3} & X \in N(p) \\ 0 & X \notin N(p) \end{cases} \quad (4.5)$$

onde, $r = X - p$.

A magnitude das forças é limitada próximo a $r = 0$ para evitar instabilidade. Outra possível definição para a força *volcano* é:

$$F_v(X) = \begin{cases} w_v \exp(-\frac{|r|^2}{\sigma_v^2}) \frac{r}{|r|} & X \in N(p) \\ 0 & X \notin N(p) \end{cases} \quad (4.6)$$

Onde, σ_v é usado para ajustar a distribuição da força *volcano*.

4.7 Fluxo do vetor gradiente

A força potencial de distância está fundamentada no princípio que um ponto do modelo deveria ser atraído em direção aos pontos mais próximos da fronteira. Este princípio, no entanto, pode causar dificuldades no comportamento dos contornos ou superfícies deformáveis frente a concavidades (Xu ; Prince, 1998b).

Um exemplo 2D desta dificuldade é mostrada na figura 4.3, onde é descrito o campo de força potencial de distância de uma região côncava. Pode-se observar a oposição de direções que existe nos pontos horizontais da concavidade. Para solucionar este problema (Xu ; Prince, 1998a) e (Xu ; Prince, 1998b) empregaram a **equação de difusão do vetor**, que propaga o gradiente do mapa de bordas para regiões distantes das fronteiras, gerando um campo de força diferente, chamado campo de fluxo do vetor gradiente (GVF). A adaptação da propagação é feita de acordo com a intensidade das fronteiras evitando assim possíveis distorções.

Figura 4.3: Um exemplo de campo de força potencial de distância em uma região côncava.

Um campo GVF é definido como a solução de equilíbrio para a seguinte equação diferencial parcial do vetor:

$$v_t = g(|\nabla f|)\nabla^2 v - h(|\nabla f|)(v - \nabla f) \quad (4.7)$$

Onde $v(x, y, 0) = \nabla f$, v_t denota a derivada de $v(x, y, t)$ com respeito a t , ∇^2 é o operador Laplaciano (aplicado para cada componente espacial de v separadamente), e f é o *edge map* com valores altos nas fronteiras dos objetos desejados, podendo ser obtido através de um detector de bordas qualquer. Um exemplo da força do campo GVF é apresentado na figura 4.4.

4.7.1 Mapa de bordas

Para definir o campo GVF, é necessário definir um *edge map* derivado da imagem $I(x, y)$, no qual os valores máximos serão encontrados nas bordas do objeto ou qualquer outra característica desejada. Existem três observações no *edge map* que merecem ser discutidas:

- O gradiente de um *edge map* ∇f tem vetores direcionados às bordas, os quais são normais ao contorno objetivo no próprio contorno.
- Os vetores geralmente têm as máximas magnitudes só na vizinhança próxima das bordas de interesse.
- Em regiões homogêneas onde $I(x, y)$ é constante, ∇f é quase zero.

Considerando o comportamento dos contornos deformáveis tradicionais utilizando o gradiente de um *edge map* como força externa tem-se: Pela primeira observação, um contorno deformável inicializado em volta da borda objetivo convergirá para uma configuração estável no alvo ou muito perto dele. Observando a segunda, o âmbito de captura geralmente será muito pequeno. Mediante a terceira observação, não existirá força externa através de regiões homogêneas.

Para o presente modelo, as duas últimas observações serão desconsideradas. A vantagem a ser desenvolvida é baseada acima da primeira, a qual ira prolongar o mapa do gradiente para regiões mais afastadas das bordas, fazendo crescer dessa forma o âmbito de atração. Um importante benefício é o tratamento que vai ser aplicado às regiões homogêneas, que com a utilização de processos de difusão computacional poderão ser criados

Figura 4.4: Um exemplo da aplicação do fluxo do vetor gradiente nos contornos deformáveis. (a) O campo da força fluxo do vetor gradiente e (b) o resultado da aplicação da força fluxo do vetor gradiente desde um contorno inicial circular.

vetores para direcionar a deformação em regiões afastadas e concavidades. Pode-se observar na figura 4.5 a diferença que existe na aplicação do modelo GVF em comparação ao modelo tradicional.

Figura 4.5: Comportamento da convergência do *edge map* tradicional e no *edge map* (GVF) respectivamente, sendo aplicados numa região côncava.

4.8 Considerações finais

Neste capítulo foram mostradas as principais forças externas utilizadas nos modelos paramétricos, as quais são responsáveis pelo movimento da curva em direção às características desejadas, neste caso as fronteiras.

A principal dificuldade deste tipo de forças é o âmbito de captura, o qual permite encaminhar a curva a se deformar a partir de regiões mais distantes. A maioria dessas forças resolve em parte o problema, mas terminam criando novas dificuldades, como por exemplo a distorção das fronteiras.

Uma força externa que permite aumentar o âmbito de captura, sem lesar as bordas de interesse foi apresentada, a força fluxo do vetor gradiente. Utilizando esta força como ponto de partida, este trabalho tenta robustecer a aplicação do modelo, e solucionar as

deficiências encontradas no tratamento de imagem ruidosas, sem perder as vantagens já adquiridas.

O modelo RGVF (*Recursive Gradient Vector Flow*)

5.1 Considerações iniciais

Neste capítulo apresenta-se o modelo RGVF sendo dividido em seis etapas de desenvolvimento. Em cada etapa serão revelados detalhes dos procedimentos aplicados, e finalmente será realizado um estudo comportamental do algoritmo.

Para o desenvolvimento deste modelo, foi utilizado o *software* MATLAB (*MATrix LABoratory*), por ser um ambiente computacional de alto desempenho fundamentado em matrizes, que integra funções de tratamento numérico e recursos gráficos sofisticados.

5.2 A metodologia

A metodologia utilizada para a segmentação de fronteiras utilizando os contornos deformáveis RGVF apresenta seis etapas, conforme a figura 5.1.

Figura 5.1: Etapas da metodologia utilizada para a obtenção do modelo deformável RGVF.

A partir da imagem de entrada é realizado um pré-processamento, visando a diminuição de ruídos e a detecção de bordas. Com a imagem filtrada e as bordas ressaltadas, realiza-se o cálculo da força externa RGVF ou *edge map*¹, a qual junto com a força interna² são utilizadas na procura da minimização da curva paramétrica³. Esta procura pela minimização de energia é chamada de processo de deformação do modelo. Finalmente os resultados obtidos da aplicação destes processos são ou a detecção de fronteiras ou a determinação da existência ou não de um objeto de interesse.

¹A força externa é desenvolvida através da energia obtida das características intrínsecas da imagem em estudo.

²A força interna é a energia da própria curva a ser deformada.

³A formulação por minimização de energia, à qual pertence este modelo, procura encontrar uma curva paramétrica que minimize a soma das energias interna e externa.

5.3 O algoritmo RGVF

Para realizar o estudo do funcionamento do modelo deformável, é apresentado o algoritmo RGVF na figura 5.2, ademais é feita uma descrição dos passos e os resultados obtidos em cada um deles.

-
- (1.) Inicialização de variáveis.
 - (1.1.) (A elasticidade, rigidez, valor da modificação por iteração).
 - (1.2.) (O valor de minimização $E(x)$ a procurar, valor mínimo de deformação).
 - (2.) Aquisição da imagem.
 - (3.) Pré-processamento.
 - (3.1.) Aplicação de filtro de detecção de bordas e suavização.
 - (4.) Cálculo da força externa RGVF.
 - (4.1.) Determinação do gradiente.
 - (4.2.) Obtenção do *Edge map*.
 - (4.3.) Normalização.
 - (5.) Processo de deformação.
 - (5.1.) Inicialização da curva de deformação.
 - (5.2.) Deformação da curva.
 - (5.3.) Interpolação de pontos.
 - (5.4.) Avaliação das sub-regiões vizinhas à nova curva.
 - (5.5.) Cálculo da força externa nas sub-regiões.[passos (3.) - (4.)].
 - (5.6.) Voltar ao passo (5.2.) até atingir o valor de minimização $E(x)$, ou o valor mínimo de deformação.
 - (6.) Resultado (a borda final ou um indicador da existência ou não de um objeto).
-

Figura 5.2: Algoritmo do modelo deformável *Recursive Gradient Vector Flow* (RGVF).

5.3.1 Inicialização de variáveis

Dentro da força interna da curva a se deformar, existem variáveis como a elasticidade, a qual permite determinar o nível de flexibilidade da curva, e a rigidez que é a variável encarregada de administrar fortes variações durante a deformação do modelo. Além destas duas variáveis, os modelos deformáveis tradicionais fazem uso de um outro parâmetro,

chamado de viscosidade ⁴. Com estes termos a energia interna manterá uma deformação vigiada e com suaves variações. Os valores aplicados para estas variáveis estão no intervalo de $[0 - 1]$.

Existem também outras variáveis importantes que o usuário deve determinar como o peso da modificação da energia por iteração e as variáveis de parada determinadas através do valor de minimização $E(x)$ esperado e o valor mínimo de deformação que é calculado pela aproximação da área sob a curva em deformação.

5.3.2 Aquisição da imagem

O processo de aquisição das imagens corresponde à construção de uma matriz representativa da imagem, onde cada coordenada dela corresponde ao valor de intensidade do *pixel*. Estes valores foram constituídos para corresponder a um intervalo de $[0 - 1]$ conforme a figura 5.3.

Figura 5.3: Matriz bidimensional representativa da imagem, gerada no processo de aquisição.

As imagens utilizadas são imagens sintéticas com ruído e imagens médicas diversas geradas a partir de raios X, tomografias computadorizadas, angiografias, ressonância magnética e ultra-som.

⁴Esta variável é também conhecida como força *damp*, a qual é inserida como parte da formulação dinâmica de forças dos modelos paramétricos, que permite determinar a velocidade de convergência da curva paramétrica.

5.3.3 Pré-processamento

O pré-processamento é constituído de procedimentos que visam preparar satisfatoriamente a imagem para uma determinada finalidade. Para este algoritmo, observou-se a necessidade de aplicar um filtro que permita suavizar a imagem e eliminar ruídos sem modificar violentamente a estrutura das bordas. Um filtro que oferece a suavização fora das bordas, sem "difundir" elas próprias, foi encontrado na técnica de espaço de escalas utilizando o processo de difusão (Perona ; Malik, 1990), (Weickert, 1994), (Weickert, 1997), o qual permite um tratamento adequado de ruídos sistemáticos e vários outros aleatórios. As figuras 5.4 e 5.5 mostram o resultado obtido através da aplicação desta técnica.

Figura 5.4: Aplicação da técnica de espaço de escalas utilizando o processo de difusão em imagens sintéticas: (a) Imagem original de um octógono, e (b) o resultado do processo utilizado recursivamente.

É importante mencionar que a técnica de espaço de escalas utilizando o processo de difusão, é aplicada suavemente na etapa inicial do pré-processamento, e conforme às necessidades do algoritmo, sua aplicação é focalizada recursivamente em sub-regiões da imagem de interesse.

Existem situações nas quais se observam imagens sem uma forte presença de ruído, em que a aplicação de um filtro detector de borda, como Sobel, é suficiente. Às vezes a aplicação de ambos também é uma boa opção no tratamento de ruídos aleatórios, pelo qual a utilização deles fica à vontade do usuário. Nas figuras 5.6 e 5.7 podem-se observar a aplicação de ambos métodos utilizados nos dois tipos de imagens: reais e sintéticas.

Figura 5.5: Aplicação recursiva da técnica de espaço de escalas utilizando o processo de difusão em imagens médicas: (a) Imagem obtida através de ressonância magnética, e o resultado é observado em (b).

Figura 5.6: Resultado do pré-processamento de uma imagem sintética, utilizando em (a) só o filtro de Sobel, e em (b) a técnica de espaço de escalas utilizando o processo de difusão mais o filtro de Sobel.

5.3.4 Cálculo da força externa RGVF

O cálculo nesta etapa do algoritmo começa com a determinação do gradiente nas coordenadas x e y da imagem, conforme pode-se observar nas figuras 5.8 e 5.9, e termina com o

Figura 5.7: Pré-processamento de uma imagem médica fazendo uso em (a) do filtro de Sobel, e em (b) a aplicação de espaço de escalas utilizando o processo de difusão ademais do filtro de Sobel.

cálculo do campo RGVF através da solução de equilíbrio⁵ da equação diferencial parcial seguinte:

$$v_t = g(|\nabla f|)\nabla^2 v - h(|\nabla f|)(v - \nabla f) \quad (5.1)$$

Onde v_t é utilizada recursivamente nos gradientes das coordenadas x e y da imagem (ver figura 5.10), e finalmente é aplicada a **normalização dos vetores**⁶ para usar a mesma medida de força nas sub-regiões da imagem que são afetadas pela difusão dos gradientes (ver figura 5.11). Este valor de determinação de sub-regiões afetadas é calculada pela função $g(|\nabla f|)$, a qual, ao assumir valores altos, a difusão fica diminuída.

5.3.5 Processo de deformação

A inicialização da curva de deformação é feita através da equação da curva, mediante a utilização das funções de seno e co-seno acima dos pontos no intervalo $[0 - 2\Pi]$ (ver figura 5.12).

⁵Esta solução de equilíbrio foi apresentada na seção 4.7 do capítulo 4.

⁶Quando é aplicada a **normalização dos vetores** nas matrizes x e y , o valor de magnitude das duas matrizes é desprezado e apenas a medida de direção (ângulo) é utilizada (vetor unitário). O cálculo da magnitude e direção do vetor pode-se observar na seção A.2 do apêndice A.

Figura 5.8: Cálculo dos gradientes, após o pré-processamento numa imagem sintética. Em (a) apresenta-se o gradiente na direção x , e em (b) o gradiente na direção y da imagem.

Figura 5.9: Cálculo dos gradientes, após o pré-processamento numa imagem médica. Em (a) apresenta-se o gradiente na direção x , e em (b) o gradiente na direção y da imagem.

A deformação começa com a determinação do seu comportamento fazendo uso dos valores de inicialização. A seguir, é avaliada a curva através do processo de interpolação, no qual realiza-se a adição de pontos onde a distância é maior que a distância máxima, e sendo feita uma remoção de pontos onde a distância é menor que a distância mínima (ver figura 5.13).

O processo de deformação tem a capacidade de mudar o *Edge map*, através da modificação das sub-regiões vizinhas da nova curva que apresentam perturbações na direção

Figura 5.10: Solução de equilíbrio v_t do sistema de equações diferenciais parciais 5.1, aplicado nas coordenadas x e y .

Figura 5.11: Aplicação da **normalização dos vetores** acima das soluções de v_t nas imagens sintética e médica respectivamente.

como mostra a figura 5.14. Este cálculo é realizado através da estimativa da média das direções e comparado com um valor máximo permitido proporcionado pelo usuário. A modificação é feita até atingir o valor permitido, mediante aplicações recursivas da técnica de espaço de escalas utilizando o processo de difusão. O processo de deformação é novamente aplicado, na procura de conseguir um valor menor ou igual proporcionado pela variável de minimização $E(x)$ conforme mostra a figura 5.15.

É importante mencionar que existe além do valor de minimização $E(x)$, um outro termo de parada, denominado "valor mínimo de deformação", o qual contém a área mínima do objeto a ser procurado. Para o processo de comparação com o valor de parada, é calculado o centro de massa da curva em deformação, e a partir desta coordenada são traçadas quatro linhas ortogonais chamadas de R_i , onde $i = 1, 2, 3$ e 4 , as quais representam quatro raios de curvas diferentes, que permitiram, mediante a media das suas áreas,

Figura 5.12: Na inicialização da curva é utilizada uma variável t com valores de 0 até 6.28 para o cálculo das coordenadas x e y como mostra-se a seguir: $x = \cos(t)$; $y = \sin(t)$.

Figura 5.13: O processo de interpolação, é realizado mediante a adição de pontos onde a distância é maior a $D = 2$, e sendo feita uma remoção onde ela é menor a $D = 2$. A distância é calculada através da adjacência por borda entre os pixels (pontos) que formam a curva paramétrica.

encontrar uma área aproximada da curva em deformação (ver figura 5.16). A estimativa é realizada mediante cálculos recursivos, acompanhando o processo de deformação. Se a estimativa ultrapassar o valor mínimo de deformação, conclui-se que não existe o elemento procurado.

Figura 5.14: Modificação das sub-regiões vizinhas à curva paramétrica que apresentam perturbações de direção. Em (a) é apresentada uma sub-região inicial, e (b) mostra a mesma sub-região modificada.

Figura 5.15: Processo de deformação aplicado recursivamente na busca por atingir a minimização $E(x)$. Em (a) apresenta-se a aplicação do modelo numa imagem sintética, e em (b) o comportamento do mesmo na imagem médica.

5.3.6 Resultados

A aplicação do algoritmo tem como saída uma curva paramétrica representando a borda de interesse dentro de uma imagem, a qual tem propriedade de suavidade e continuidade como é mostrado na figura 5.17 e a figura 5.18.

Dependendo da ativação do valor mínimo de deformação, pode-se gerar uma resposta de classificação, mediante a qual o algoritmo determine a presença ou ausência de um objeto de interesse na imagem como pode-se observar na figura 5.19.

Figura 5.16: Processo de deformação utilizando o valor mínimo de deformação. Em (a) apresenta-se uma imagem de ultra-som. Em (b) é apresentado em forma gráfica o valor mínimo de deformação fornecido pelo usuário. Na imagem (c) observa-se a execução do processo de comparação (cálculo do centro de massa, e dos raios das curvas). Finalmente na imagem (d) apresenta-se a localização do objeto ao encontrar a minimização da curva $E(x)$ antes de atingir o valor mínimo de deformação.

Figura 5.17: Resultado da aplicação do modelo RGVF na procura da minimização da curva paramétrica $E(x)$ em uma imagem sintética: (a) Imagem sintética. (b) Imagem pré-processada. (c) Execução do processo de deformação. (d) Obtenção da borda do objeto de interesse.

Figura 5.18: Aplicação do modelo RGVF para a minimização da curva paramétrica $E(x)$ em imagens médicas: (a) Imagem médica a ser processada. (b) Imagem pré-processada. (c) Execução do processo de deformação. (d) Obtenção da borda do objeto de interesse.

Figura 5.19: Aplicação do modelo RGVF para detecção de objetos em imagens médicas: Em (a) é apresentada uma imagem de ultra-som, na qual observa-se a presença de um tumor, o qual é detectado como observa-se na figura (b). Já na figura (c) é avaliada uma imagem ultra-som sem presença de objetos de interesse, e em (d) observa-se a resposta da não existência de objetos maiores ao **valor mínimo de deformação**.

Resultados e conclusões

6.1 Considerações iniciais

Neste capítulo, apresenta-se os resultados e conclusões da aplicação do algoritmo RGVF na segmentação de fronteiras e classificação de imagens médicas. No processo de segmentação de fronteiras foram utilizadas imagens geradas a partir de raios X, tomografias computadorizadas, angiografias, ressonância magnética e ultra-som. Já no processo de classificação, foi utilizado um banco de imagens mamográficas para avaliar o algoritmo na determinação da presença ou ausência de nódulos. Finalmente, são apresentadas conclusões e propostas para futuros trabalhos nesta área de pesquisa.

6.2 Resultados da aplicação

A avaliação do modelo RGVF é dividido em duas etapas operacionais. A primeira etapa, avalia o comportamento do modelo na detecção de fronteiras, e na segunda etapa o algoritmo é observado como um ente classificador de imagens médicas.

No processo de detecção de fronteiras, as imagens utilizadas têm uma resolução de 8 bits, as quais foram geradas a partir de ressonância magnética, raios X, tomografias computadorizadas, angiografias e ultra-som. Pode-se observar o comportamento do modelo RGVF e do GVF tradicional nas figuras 6.1, 6.2, 6.3, 6.4 e 6.5.

Figura 6.1: Processo de detecção de fronteiras, aplicado numa imagem gerada a partir de ressonância magnética: (a) Imagem médica a ser processada. (b) Localização da curva inicial. (c) O *Edge map* do modelo RGVF, depois de ser aplicado de forma iterativa nas sub-regiões de interesse. (d) Bordas encontradas com o modelo RGVF, utilizando $\mu = 0.2$. (e) O *Edge map* do modelo GVF. (f) Borda final encontrada pelo modelo GVF.

Dos resultados obtidos, conclui-se que o desempenho do modelo não decai mesmo sendo aplicado em imagens médicas de características diversas. Esse comportamento

Figura 6.2: Processo de detecção de fronteiras, aplicado numa imagem gerada a partir de raios X: (a) Imagem médica a ser processada. (b) Localização da curva inicial. (c) O *Edge map* do modelo RGVF, depois de ser aplicado de forma iterativa nas sub-regiões de interesse. (d) Bordas encontradas com o modelo RGVF, utilizando $\mu = 0.05$. (e) O *Edge map* do modelo GVF. (f) Borda final encontrada pelo modelo GVF.

robusto que apresenta o modelo, é consequência lógica do fortalecimento das etapas de **Pré-processamento** e **Cálculo da força externa (RGVF)**, o que facilita o tratamento de perturbações geradas por falsas fronteiras e ruídos diversos, sendo esta a principal vantagem frente à aplicação do modelo tradicional GVF.

Na segunda etapa, correspondente ao processo de classificação de imagens médicas, foi utilizado um banco de imagens de mamografias fornecido pelo Laboratório de Análise

Figura 6.3: Processo de detecção de fronteiras, aplicado numa imagem de tomografia computadorizada: (a) Imagem médica a ser processada. (b) Localização da curva inicial. (c) O *Edge map* do modelo RGVF, depois de ser aplicado de forma iterativa nas sub-regiões de interesse. (d) Bordas encontradas com o modelo RGVF, utilizando $\mu = 0.05$. (e) O *Edge map* do modelo GVF. (f) Borda final encontrada pelo modelo GVF.

e Processamento de Imagens Médicas e Odontológicas (LAPIMO) da Escola de Engenharia de São Carlos - Universidade de São Paulo. As imagens avaliadas foram em número de 83, sendo 71 imagens de nódulos classificadas assim pelo especialista, e 12 imagens mamográficas sem nódulos. Essas imagens têm uma dimensão de 200×200 *pixels*, contendo o correspondente local de interesse.

Figura 6.4: Processo de detecção de fronteiras, aplicado numa imagem angiográfica: (a) Imagem médica a ser processada. (b) Localização da curva inicial. (c) O *Edge map* do modelo RGVF, depois de ser aplicado de forma iterativa nas sub-regiões de interesse. (d) Bordas encontradas com o modelo RGVF, utilizando $\mu = 0.08$. (e) O *Edge map* do modelo GVF. (f) Borda final encontrada pelo modelo GVF.

A partir da utilização do banco de dados todo, o algoritmo detectou corretamente 77 imagens, o que corresponde a uma taxa de acerto de 93%. Os resultados obtidos foram de 4 imagens classificadas como falso positivo e 2 imagens como falso negativo.

Das 6 imagens que não foram classificadas corretamente, observou-se características muito similares: O principal problema foi a falta de nitidez, ocasionando que a informação procurada seja considerada como ruído e falsas fronteiras, ocasionando que o modelo não

Figura 6.5: Processo de detecção de fronteiras, aplicado numa imagem de ultra-som: (a) Imagem médica a ser processada. (b) Localização da curva inicial. (c) O *Edge map* do modelo RGVF, depois de ser aplicado de forma iterativa nas sub-regiões de interesse. (d) Bordas encontradas com o modelo RGVF, utilizando $\mu = 0.4$. (e) O *Edge map* do modelo GVF. (f) Borda final encontrada pelo modelo GVF.

determine a presença de nódulos. Já no caso dos falsos positivos, o alto contraste que apresentava o ruído nas imagens avaliadas, ocasionou no algoritmo a determinação errada de possíveis nódulos. A figura 6.6 mostra um exemplo das imagens com problemas de classificação.

A figura 6.7 ilustra uma imagem onde o algoritmo realizou uma classificação correta. Esta imagem, mesmo apresentando problemas de ruído e contraste, foi favorecida pela ini-

Figura 6.6: Imagem determinada como falso positivo na etapa de classificação da presença de nódulos.

cialização da curva que permitiu detectar a presença de nódulos. Assim, pode-se observar, que o algoritmo, da mesma forma que no processo de detecção de fronteiras, consegue se comportar eficientemente com base na determinação adequada da inicialização da curva.

Figura 6.7: Imagem classificada corretamente como verdadeiro positivo pelo processo de classificação.

6.3 Conclusões e principais apreciações

Pode-se observar no modelo proposto um fortalecimento na utilização das características da imagem, mediante a utilização do fluxo de vetores para amoldar as características de importância (cálculo do campo RGVF).

Os algoritmos que utilizam a força externa tradicional GVF não acompanham o processo de deformação, pelo qual, o cálculo do *Edge map* é aplicado na área toda da imagem. Com o desenvolvimento do modelo proposto, o cálculo do *Edge map* é direcionado em sub-regiões de interesse, o que reduz o número de interações necessárias.

Os campos de força externa gerados a partir do algoritmo GVF, no apoio ao processo de deformação, só fazem uso das características da própria imagem. Já nos campos RGVF a informação *a priori* vai além das características da própria imagem, aprovei-

tando o comportamento dos fluxos de vetores e reorganizando os mesmos, para eliminar os problemas de desorientação.

O modelo GVF, mesmo tenha sido desenvolvido com a característica de suportar uma inicialização afastada das bordas de interesse, não foi projetado para um robusto tratamento de obstáculos, o que ocasiona, muitas vezes resultados não válidos. O modelo proposto, sem embargo, permite um tratamento robusto de ruídos e falsas fronteiras, garantindo uma convergência bem sucedida.

Os resultados obtidos através de imagens sintéticas e médicas diversas, sugerem que a família do modelo GVF (incluído o modelo proposto) facilita a utilização de ferramentas que permitam desprezar gradientes fracos e o fortalecer gradientes fortes, o qual faz dos modelos deformáveis ter uma robusta execução em imagens com ruído.

6.3.1 Trabalhos futuros

Existem diversas pesquisas que o desenvolvimento do modelo RGVF deixa em aberto, principalmente, na avaliação do comportamento do *Edge map*, na qual poderia se incorporar uma modificação automática de pesos por iteração, dependendo do tipo de imagem, além da determinação do valor de parada (valor de minimização $E(x)$).

Um outro ponto importante de estudo, na deformação do modelo, é a determinação do local de inicialização, o qual afeta diretamente o comportamento e a convergência do modelo.

Finalmente, este modelo proposto, poderia ajudar na definição de um modelo deformável RGVF interativo, sugerindo a incorporação de pontos de influência ou na evolução de um modelo geométrico que facilite as mudanças topológicas.

6.3.2 Perspectiva global

O principal objetivo desta dissertação foi avaliar a aplicação dos modelos deformáveis na área médica e contribuir, através do desenvolvimento do modelo RGVF, no estudo comportamental do *Edge map* e as necessidades de explorar mais ainda as características que ele oferece. Espera-se que esta pesquisa ajude ao entendimento dos modelos deformáveis e seja uma orientação para futuras modificações e aplicações em áreas diversas.

Referências

- Abrantes, A. ; Marques, J. (1996). A class of constrained clustering algorithms for object boundary extraction. *IEEE Trans. on Image Processing*, 5(11):1507–1521.
- Adalsteinsson, D. ; Sethian, J. (1999). The fast construction of extension velocities in level set methods. *J. Computational Physics*, 148:2–22.
- Alvarez, L., Guichard, F., Lions, P., ; Morel, J. (1993). Axioms and fundamental equations of image processing. *Archive for Rational Mechanics and Analysis*, 123(3):199–257.
- Artero, A. (1999). *Técnicas para extração automática de feições retas em imagens digitais*. Universidade Estadual Paulista, Presidente Prudente, SP.
- Ayache, N., Cinquin, P., Cohen, I., Cohen, L., Leitner, F., ; Monga, O. (1996). *Segmentation of complex three-dimensional medical objects: a challenge and a requirement for computer-assisted surgery planning and performance*. MIT Press.
- Borgefors, G. (1984). Distance transformations in arbitrary dimensions. *Comp. Graph. Imag. Proc.*, 27:321–345.
- Brito, S. (1998). *Estudo, seleção e implementação de algoritmos de segmentação*. Universidade Federal de Paraíba - UFPB, <http://www.dee.ufcg.edu.br/acsi/relatorios.html>.
- Broit, C. (1981). *Optimal registration of deformed images*. Ph.d. thesis, Computer and Information Science Dept., University of Pennsylvania, Philadelphia, PA.
- Caselles, V., Catto, F., Coll, T., ; Dibos, F. (1993). A geometric model for active contours. *Numerische Mathematik*, (66):1–31.

- Caselles, V., Kimmel, R., ; Sapiro, G. (1997). Geodesic active contours. *Int. J. Computer Vision*, 22:61–79.
- Cohen, L. (1991). On active contour models and balloons. *CVGIP: Image Understanding*, 53(2):211–218.
- Cohen, L. ; Cohen, I. (1993). Finite-element methods for active contour models and balloons for 2-d and 3-d images. *IEEE Trans. on Pattern Anal. Machine Intell.*, 15(11):1131–1147.
- Cootes, T., Hill, A., Taylor, C., ; Haslam, J. (1994). Use of active shape models for locating structures in medical images. *Imag. Vision Computing J.*, 12(6):355–366.
- Cootes, T., Taylor, C., Cooper, D., ; Graham, J. (1995). Active shape models - their training and application. *Computer Vision Imag. Under.*, 61(1):38–59.
- Courant, R. ; Hilbert, D. (1953). Methods of mathematical physics. *Interscience*, 1.
- Danielsson, P. (1980). Euclidean distance mapping. *Comp. Graph. Imag. Proc.*, 14:227–248.
- Davatzikos, C. ; Prince, J. (1995). An active contour model for mapping the cortex. *IEEE Trans. Med. Imag.*, 14:65–80.
- Delingette, H. (1994). Simplex meshes: a general representation for 3d shape reconstruction. *Tech. Rep. TR2214, INRIA*.
- Durikovic, R., Kaneda, K., ; Yamashita, H. (1995). Dynamic contour: a texture approach and contour operations. *The Visual Computer*, (11):277–289.
- Gonzales, R. ; Woods, R. (1992). *Digital image processing*. Addison - Wesley Publishing Company.
- Grayson, M. (1989). Shortening embedded curves. *Annals of Mathematics*, 129:71–111.
- Grimson, W., Ettinger, G., Kapur, T., Leventon, M., ; Wells, W. (1997). Utilizing segmented mri data in image-guided surgery. *Int. J. Patt. Recog. Artificial Intell.*, 11:1367–1397.
- INPE (2001). *Processamento de imagens*. Instituto Nacional de Pesquisas Espaciais - INPE, <http://www.dpi.inpe.br/spring/CURSO/>.

- Jain, R., Kasturi, R., ; Schunck, B. (1995). *Machine Vision*. McGraw-Hill, Singapore.
- Jorge, L. (2001). *Reconhecimento automático da cobertura do solo em fotografias aéreas obtidas no projeto ARARAS*. Universidade de São Paulo - USP, São Carlos - SP.
- Kass, M., Witkin, A., ; Terzopoulos, D. (1988). Snakes: Active contour models. *Int. J. Computer Vision*, 1(4):321–331.
- Khoo, V., Dearnaley, D., Finnigan, D., Padhani, A., Tanner, S., ; Leach, M. (1997). Magnetic resonance imaging (mri): considerations and applications in radiotherapy treatment planning. *Radiother. Oncol.*, 42:1–15.
- Kimia, B. (1990). *Conservation Laws and a Theory of Shape*. Ph.D. thesis. McGill Centre for Intelligent Machines, Montreal, Canada.
- Kimia, B., Tannenbaum, A., ; Zucker, S. (1995). Shapes, shocks, and deformations i: the components of two-dimensional shape and the reaction-diffusion space. *Int. J. Computer Vision*, 15:189–224.
- Kimmel, R., Amir, A., ; Bruckstein, A. (1995). Finding shortest paths on surfaces using level sets propagation. *IEEE Trans. Patt. Anal. Mach. Intell.*, 17(6):635–640.
- Levine, M. (1985). *Vision in Man and Machine*. McGraw-Hill.
- Leymarie, F. ; Levine, M. (1993). Tracking deformable objects in the plane using an active contour model. *IEEE Trans. on Pattern Anal. Machine Intell.*, 15(6):617–634.
- Llapa-Rodríguez, E. ; Gonzaga, A. (2003a). Segmentación de imágenes médicas: Modelos deformables. *XI Jornada Internacional de Ingeniería de Sistemas (JINIS'03)*, Arequipa, Perú.
- Llapa-Rodríguez, E. ; Gonzaga, A. (2003b). Segmentação automática de imagens médicas via contornos deformáveis por fluxo do vetor gradiente. *II Workshop Regional de Engenharia Biomédica, São Pedro - SP, Brasil*.
- MacDonald, D., Avis, D., ; Evans, A. (1994). Multiple surface identification and matching in magnetic resonance images. *SPIE Proc. Visualization in Biomedical Computing*, 2359:160–169.
- Malladi, R., Sethian, J., ; Vemuri, B. (1995). Shape modeling with front propagation: A level set approach. *IEEE Trans. on Pattern Anal. Machine Intell.*, 17(2):158–175.

- McInerney, T. ; Terzopoulos, D. (1995). A dynamic finite element surface model for segmentation and tracking in multidimensional medical images with application to cardiac 4-d image analysis. *Computerized Medical Imaging and Graphics*, 19(1):69–83.
- McInerney, T. ; Terzopoulos, D. (1996). Deformable models in medical image analysis: a survey. *Medical Image Analysis*, 1(2):91–108.
- Miller, J., Breen, D., Lorensen, W., O’Bara, R., ; Wosny, M. (1991). Geometrically deformed models: A method for extracting closed geometric models from volume data. *Computer Graphics (SIGGRAPH’91)*, 25(4):217–226.
- Muller-Gartner, H., Links, J., Prince, J., Bryan, R., McVeigh, E., Leal, J., Davatzikos, C., ; Frost, J. (1992). Measurement of radiotracer concentration in brain gray matter using positron emission tomography: Mri-based correction for partial volume effects. *J. Cereb. Blood Flow Metab.*, 12:571–583.
- Nastar, C. ; Ayache, N. (1996). Frequency-based nonrigid motion analysis: application to four dimensional medical images. *IEEE Trans. Patt. Anal. Mach. Intell.*, 18:1067–1079.
- Osher, S. ; Sethian, J. (1988). Fronts propagating with curvature-dependent speed: algorithms based on hamilton-jacobi formulations. *J. Computational Physics*, 79:12–49.
- Pentland, A. ; Horowitz, B. (1991). Recovery of nonrigid motion and structure. *IEEE Trans. Patt. Anal. Mach. Intell.*, 13:730–742.
- Perona, P. ; Malik, J. (1990). Scale space and edge detection using anisotropic diffusion. *IEEE Trans. Pattern Anal. Mach. Intell.*, 12:629–639.
- Sahoo, P., Soltani, S., ; Wang, A. (1988). An survey of thresholding techniques. *Computer Vision, Graphics and Image Processing*, 41:233–260.
- Sapiro, G. ; Tannenbaum, A. (1993). Affine invariant scale-space. *Int. J. Computer Vision*, 11:25–44.
- Schalkoff, R. (1989). *Digital Image Processing and Computer Vision*. John Wiley and Sons, New York, NY.
- Sethian, J. (1982). *An Analysis of Flame Propagation*. *Ph.D. thesis*. University of California, Berkeley, CA.
- Sethian, J. (1985). Curvature and evolution of fronts. *Commun. Math. Phys.*, 101:487–499.

- Sethian, J. (1989). A review of recent numerical algorithms for hypersurfaces moving with curvature dependent speed. *J. Differential Geometry*, 31:131–161.
- Sethian, J. (1999). *Level Set Methods and Fast Marching Methods: Evolving Interfaces in Computational Geometry, Fluid Mechanics, Computer Vision, and Material Science*. Cambridge University Press, Cambridge, UK, 2nd edition.
- Staib, L. ; Duncan, J. (1992). Boundary finding with parametrically deformable models. *IEEE Trans. Patt. Anal. Mach. Intell.*, 14(11):1061–1075.
- Taylor, P. (1995). Invited review: computer aids for decision-making in diagnostic radiology - a literature review. *Brit. J. Radiol.*, 68:945–957.
- Terzopoulos, D. ; Fleischer, K. (1988). Deformable models. *The Visual Computer*, 4(6):306–331.
- Terzopoulos, D. ; Metaxas, D. (1991). Dynamic 3d models with local and global deformations: deformable superquadrics. *IEEE Trans. Patt. Anal. Mach. Intell.*, 13:703–714.
- Terzopoulos, D. ; Szeliski, R. (1992). *Tracking with Kalman snakes*. The MIT Press, Cambridge, Massachusetts, 1st edition.
- Terzopoulos, D., Witkin, A., ; Kass, M. (1988). Constraints on deformable models: recovering 3d shape and nonrigid motion. *Artificial Intelligence*, 36(1):91–123.
- Vemuri, B. ; Radisavljevic, A. (1994). Multiresolution stochastic hybrid shape models with fractal priors. *ACM Trans. on Graphics*, 13(2):177–207.
- Weickert, J. (1994). Anisotropic diffusion filters for image processing based quality control. In *Proc. Seventh European Conf. on Mathematics in Industry*, pages 355–362.
- Weickert, J. (1997). A review of nonlinear diffusion filtering. in scale-space theory in computer vision. *Lecture Notes in Computer Science*, 1252:3–28.
- Worring, M., Smeulders, A., Staib, L., ; Duncan, J. (1993). Parameterized feasible boundaries in gradient vector fields. *Information Processing in Medical Imaging (IPMI'93)*.
- Xu, C. ; Prince, J. (1997). Gradient vector flow: A new external force for snakes. *IEEE Proc. Conf. on Comput Vis. Patt. Recog. (CVPR)*, pages 66–71.
- Xu, C. ; Prince, J. (1998a). Generalized gradient vector flow external forces for active contours. *Signal Processing - An International Journal*, 71(2):131–139.

- Xu, C. ; Prince, J. (1998b). Snakes, shapes, and gradient vector flow. *IEEE Trans. Imag. Proc.*, 7(3):359–369.
- Zijdenbos, A. ; Dawant, B. (1994). Brain segmentation and white matter lesion detection in mr images. *Critical Reviews in Biomedical Engineering*, 22:401–465.

Técnicas tradicionais de segmentação de imagens

A segmentação consiste na subdivisão de uma imagem em suas partes constituintes ou objetos, onde um objeto, neste contexto, refere-se a uma componente conexa.

Nesta seção são apresentadas diversas técnicas utilizadas no processamento de imagens, entre as principais pode-se citar:

- A técnica de limiarização - *threshold*;
- A técnica para detecção de bordas;
- A segmentação por região; e
- A segmentação por cor;

A.1 Técnica de limiarização - *threshold*

Threshold é uma operação que tem por objetivo classificar os *pixels* de uma imagem em duas classes distintas, normalmente, objetos e o fundo (Gonzales ; Woods, 1992), (Jain et al., 1995), (Schalkoff, 1989).

O processamento é feito da seguinte forma: um valor (limiar) é determinado após alguma análise dos valores dos níveis de cinza da imagem. *Pixels* com valores de brilho inferiores a esse limiar são colocados em uma classe enquanto *pixels* com valores superiores ou iguais são colocados em outra (Artero, 1999), (Jain et al., 1995).

A determinação de um limiar ótimo não é uma tarefa simples. Existem vários métodos propostos para a obtenção do valor limiar adequado, entre eles destacam-se: P-Tile, Método de Pun, Método de Kapur, Método de Sahoo e Wong, Método de Johannsen e Bille e Método do Triângulo (Sahoo et al., 1988).

Como ferramenta auxiliar para diversas operações, é comum a utilização de histogramas que permitem uma visualização da distribuição dos níveis de cinza nas imagens.

Em alguns casos é mais conveniente trabalhar com uma imagem que contenha apenas dois níveis de cinza (imagem binária). Neste caso, *pixels* com valores de brilho inferiores ao limiar recebem valor 0 (zero), e *pixels* com valores superiores ou iguais recebem o valor 1 (um). A figura A.1 ilustra o processo de binarização de uma imagem.

Figura A.1: Processo de binarização por *threshold*.

Para o cálculo da imagem resultante $f_t(x, y)$ utiliza-se a regra:

$$f_t(x, y) = \begin{cases} 1 & \text{se } f(x, y) \geq T \\ 0 & \text{se } f(x, y) < T \end{cases} \quad (\text{A.1})$$

sendo T , o valor limiar dos *pixels* da imagem utilizado para determinação dos valores (0 e 1).

A.1.1 Histograma

Em processamento de imagens, a utilização de histogramas não se resume apenas em operações de limiarização / binarização. É comum a utilização de histogramas em várias outras operações com o objetivo de melhorar alguma característica da imagem. Algumas operações são realizadas através de uma manipulação direta do histograma. Uma dessas operações é a equalização, que altera a distribuição dos níveis de cinza (Jain et al., 1995), (INPE, 2001). Esta distribuição dos níveis de cinza é utilizada para obter um histograma uniforme, melhorar o aspecto da imagem e como consequência tornar a interpretação mais fácil.

O histograma de uma imagem $f(x, y)$, com n níveis de cinza, é representado por um vetor unidimensional V de n elementos. Inicialmente, todos os elementos desse vetor recebem o valor 0 (zero). O elemento V_i dessa reta é incrementado de 1 sempre que um nível de cinza igual a n é encontrado na imagem.

A equalização do histograma pode ser obtida por:

$$S = \left(\sum_{i=0}^n \frac{m_i}{I} \right) - 1 \quad (\text{A.2})$$

Onde:

- S , corresponde ao nível de cinza do *pixel* que está sendo equalizado.
- n são os níveis de cinza da imagem original.
- m_i é a frequência do nível de cinza i .
- I é definido pelo número de *pixels* e os níveis de cinza utilizados.

Para a equalização de uma imagem contendo 30 *pixels* ($x \times y$), com 9 níveis de cinza (n):

$$I = \frac{xy}{n} = \frac{30}{9} = 3 \quad (\text{A.3})$$

O processo de equalização de uma imagem é apresentado na figura A.2.

Figura A.2: Processo de equalização da imagem.

A.2 Técnica para detecção de bordas

As bordas de uma imagem definem o limite entre duas regiões distintas com referência às propriedades de cor ou nível de cinza. Quando ocorre uma mudança bastante brusca de um valor de nível de cinza para outro (alta frequência), entende-se que há presença de borda. Isso contribui para a detecção de formas e análise de objetos (Gonzales ; Woods, 1992).

A.2.1 Técnica de Sobel

A técnica de Sobel, na detecção das bordas de uma imagem, utiliza duas máscaras distintas, uma para o eixo X e outra para o eixo Y . Ela considera o somatório dos *pixels*

da imagem multiplicados pelo coeficiente da máscara. Este somatório é utilizado para os cálculos da magnitude do gradiente e direção da borda (Gonzales ; Woods, 1992), (Artero, 1999).

As máscaras utilizadas no operador de Sobel podem ser vistas na figura A.3 (Jain et al., 1995), (Artero, 1999).

-1	0	1
-2	0	2
-1	0	1

S_x

1	2	1
0	0	0
-1	-2	-1

S_y

Figura A.3: Máscaras de Sobel.

A aplicação dos dois operadores S_x e S_y (primeira derivada), resulta nos gradientes da borda na direção x e y , e por meio destes, é possível obter a magnitude e a direção (ângulo) da borda em cada *pixel* (Artero, 1999), (Gonzales ; Woods, 1992) mediante:

$$Magnitude = \sqrt{S_x^2 + S_y^2} \quad (A.4)$$

$$\alpha = \arctan \frac{S_y}{S_x} \quad (A.5)$$

A determinação da magnitude e da direção das bordas pode ser vista de forma gráfica na figura A.4.

Figura A.4: Determinação da magnitude e da direção da borda.

Deve-se ressaltar que as máscaras são baseadas no operador diferencial. Elas podem resultar em valores nulos nas regiões homogêneas, indicando que o *pixel* em estudo não pertence a uma borda (Artero, 1999), (Jain et al., 1995).

Os operadores diferenciais destacam os contornos das bordas, e também o ruído da cena. A maioria dos operadores de borda utiliza algum tipo de suavização da imagem antes da operação diferencial (filtro) (Artero, 1999), (Schalkoff, 1989).

O resultado da aplicação dos operadores de Sobel sobre uma imagem pode ser visto na figura A.5.

Figura A.5: Aplicação dos operadores de Sobel sobre uma imagem.

A.2.2 Técnica de Laplace

Enquanto a técnica de Sobel emprega derivadas de primeira ordem, ou seja, gera dois gradientes da imagem (S_x e S_y), o Laplaciano de uma função bi-dimensional $f(x, y)$ é formado por derivadas de segunda ordem, sendo definido por (Gonzales ; Woods, 1992), (Jain et al., 1995), (Schalkoff, 1989):

$$\nabla^2 f(x, y) = \frac{\partial^2 f(x, y)}{\partial x^2} + \frac{\partial^2 f(x, y)}{\partial y^2} \quad (\text{A.6})$$

Da mesma forma que a técnica de Sobel utiliza máscaras para o cálculo dos gradientes, o Laplaciano utiliza a máscara mostrada na figura A.6 (Gonzales ; Woods, 1992), (Jain et al., 1995), (Schalkoff, 1989), (Brito, 1998).

O Laplaciano $R(x, y)$ (imagem resultante), é nulo se $f(x, y)$ for constante ou variar linearmente em amplitude. Se a taxa de variação de $f(x, y)$ for maior que a de uma função linear, $R(x, y)$ exibe uma mudança de sinal, indicando que *pixels* vizinhos têm o mesmo

Figura A.6: Máscara de Laplace.

valor. Dessa forma a derivada passa por zero, detectando a presença de uma borda (Brito, 1998), (Gonzales ; Woods, 1992).

A aproximação mais simples para o Laplaciano consiste no cálculo das diferenças das derivadas em cada posição da imagem de acordo com a expressão abaixo (Brito, 1998):

$$R(x, y) = [f(x, y) - f(x, y - 1)] - [f(x, y + 1) - f(x, y)] + [f(x, y) - f(x + 1, y)] - [f(x - 1, y) - f(x, y)]$$

Por ser uma derivada de segunda ordem, o Laplaciano é bastante sensível ao ruído, o que representa uma desvantagem. Mesmo assim, ele pode auxiliar na determinação precisa da borda (Gonzales ; Woods, 1992), (Jain et al., 1995).

O resultado da aplicação do operador Laplaciano sobre uma imagem pode ser visualizado na figura A.7.

Figura A.7: Aplicação do operador Laplaciano.

A.2.3 Formação de contornos

Um contorno é definido como o caminho obtido através da conexão dos *pixels* de borda encontrados em uma dada região da imagem (Jain et al., 1995). Para a representação de

um contorno, são armazenados os valores das coordenadas x e y de cada *pixel* do caminho percorrido. É possível definir se o contorno é aberto ou fechado. Se o *pixel* inicial for igual ao final, tem-se um contorno fechado; caso contrário tem-se um contorno aberto (Schalkoff, 1989).

Descontinuidades podem ocorrer na fronteira de uma região devido a problemas de contraste, dificultando a detecção do contorno completo (Jain et al., 1995).

A segmentação por contorno fundamenta-se exclusivamente nas bordas da imagem, logo, para que o contorno seja realmente encontrado as bordas necessitam estar bem definidas (Schalkoff, 1989), (Jain et al., 1995). Quando isso não ocorre, podem ser utilizadas operações como a equalização do histograma da imagem.

Vários algoritmos podem ser utilizados para determinar o caminho do contorno. O mais conhecido é o algoritmo de perseguição de contorno (*Contour Following Algorithm*). Este algoritmo inicia uma varredura na primeira linha da imagem e segue até encontrar o primeiro *pixel* da borda. Em seguida procura na vizinhança o próximo *pixel* do contorno, repetindo este passo até encontrar o *pixel* inicial (contorno fechado) ou até não ser possível continuar (contorno aberto) (Jain et al., 1995).

A figura A.8 mostra uma representação esquemática do processo de busca do contorno sobre uma determinada imagem:

Figura A.8: Processo de busca do contorno de uma imagem.

A.3 Segmentação por região

Uma região da imagem é um conjunto de *pixels* conectados que apresentam uma certa homogeneidade. Por homogeneidade entende-se um conjunto de *pixels* com valores de níveis de cinza ou cor similares.

A segmentação de uma imagem por regiões consiste na sua divisão e subdivisão de regiões menores, levando-se em consideração a homogeneidade desejada. Desta forma, a imagem original está relacionada com suas partes através da seguinte expressão:

$$\bigcup_{i=1}^n R_i = f(x, y) \quad (\text{A.7})$$

em que, $\bigcup_{i=1}^n R_i$ corresponde à união de todas as regiões, e $f(x, y)$ à imagem total.

Nesse tipo de segmentação encontram-se alguns problemas, por exemplo, dado um conjunto de *pixels* da imagem $f(x, y)$ e uma homogeneidade $H(R_i)$, encontrar uma partição S da imagem $f(x, y)$ dentro de um conjunto de n regiões R (Jain et al., 1995), (Gonzales ; Woods, 1992):

A homogeneidade H das partições R_i da imagem têm a seguinte propriedade:

$$H(R_i) = \textit{Verdadeiro} \quad (\text{A.8})$$

$$H(R_i \cup R_j) = \textit{Falso} \quad (\text{A.9})$$

com i diferente de j .

A homogeneidade $H(R_i)$ define a conformidade de todos os *pixels* da região R_i para com o modelo da região (Jain et al., 1995).

Vários métodos podem ser utilizados para segmentar uma imagem por regiões. Alguns são apresentados nesta seção, como o de crescimento de região, partição de região e o de divisão e fusão.

A.3.1 Crescimento de região

O crescimento de região consiste em agrupar *pixels* ou sub-regiões em regiões maiores. Essa agregação inicia com um *pixel* (semente), e a partir dele, são anexados *pixels* vizinhos que possuem propriedades similares, como por exemplo, nível de cinza, cor e *pixels* pertencentes a um mesmo padrão de textura. O processo se repete também para os *pixels* anexados. Quando um *pixel* não apresenta propriedades similares, define-se uma nova região (Gonzales ; Woods, 1992).

É possível fazer o crescimento de regiões por varredura ou por busca em todas as direções. Cada *pixel* é comparado com seus vizinhos anteriores já rotulados sendo adicionado ou não à região de um dos vizinhos.

A.3.2 Partição de região

Essa técnica consiste na partição da imagem em N blocos ($N = 2^i$), considerando propriedades como por exemplo nível de cinza, cor e padrão de textura.

Para o início da partição normalmente utilizam-se dois *pixels* que resultam em duas regiões R_1 e R_2 . Para continuar o processo de partição é verificada a propriedade de homogeneidade. Caso o *pixel* não pertença a uma região já subdividida, o processo de partição é novamente realizado (Gonzales ; Woods, 1992), (Jain et al., 1995).

A técnica de *quadtree* é bastante utilizada na representação da estrutura de particionamento de uma região. A figura A.9 mostra a técnica de *quadtree*.

Figura A.9: Processo de crescimento de região.

A imagem original R constitui a raiz da árvore. Após verificar a homogeneidade de R , realiza-se a partição da imagem em quatro regiões (R_1, R_2, R_3 e R_4). Tais regiões constituem o primeiro nível da árvore. Em seguida é verificada a homogeneidade de cada região menor. Na figura A.9, R_1, R_2 , e R_3 contêm a homogeneidade desejada, enquanto que R_4 precisa ser novamente dividida em quatro regiões, gerando mais um nível na árvore (Gonzales ; Woods, 1992), (Jain et al., 1995).

A.3.3 Divisão e fusão de regiões

Este método complementa o anterior, realizando a fusão de regiões adjacentes que apresentem características similares. Novamente a estrutura *quadtree* pode ser utilizada para representar o processo de segmentação (Gonzales ; Woods, 1992). A figura A.10 (da esquerda à direita), representa uma imagem dividida, as regiões que podem ser fundidas, depois o resultado das operações de divisão e fusão e finalmente o resultado final, onde todas as regiões satisfazem a homogeneidade desejada a partir da última operação de divisão e fusão.

Figura A.10: Processo de divisão e fusão de uma imagem.

A.4 Segmentação por cor

A capacidade da percepção de cores possibilita ao ser humano um melhor entendimento do mundo que o cerca, proporcionando maior capacidade de autoproteção, localização e compreensão do ambiente (Levine, 1985).

A percepção de várias faixas do espectro de luz no sistema visual humano é baseada em sensores que apresentam diferentes respostas ao estímulo luminoso. Na retina do olho humano existem três tipos de sensores, que respondem de maneira distinta ao estímulo luminoso (maior resposta nas cores azul, vermelho ou verde). A interação entre as respostas destes sensores dá origem à sensação de cor (Levine, 1985), (Jorge, 2001).

A luminosidade é uma propriedade particular de um objeto associado à quantidade de luz refletida por ele. O brilho é uma propriedade que depende da iluminação sobre o objeto (Jorge, 2001), (Levine, 1985), (Jain et al., 1995). Se o objeto reflete mais luz, ele pode parecer mais claro, ou se absorve quase toda a luz, pode parecer mais escuro. Em certas condições, a luminosidade (branco ou preto) e o brilho (claro ou escuro) são difíceis de serem distinguidos visualmente.

A visão de cores do ser humano permite uma grande capacidade de percepção e discriminação de objetos. A percepção e a separação dessas cores requerem um estágio de aprendizagem. O convívio social do ser humano influi na formação de vários conceitos e, um deles é a interpretação das cores (Levine, 1985). A percepção da cor resulta da combinação de alguns fatores: as características físicas do próprio objeto, a parte do espectro luminoso refletida ou absorvida, as propriedades espectrais da fonte de luz que ilumina o objeto, as propriedades do sistema visual e a experiência prévia com o objeto, e a sensação de cor (Jorge, 2001).

A tonalidade de uma cor pode ser alterada com a mistura da cor branca, alterando a propriedade de saturação. Quanto menos branco mais saturada é a cor. Essa percepção de saturação corresponde ao conceito de pureza de uma cor (Jain et al., 1995), (Jorge, 2001).

A cor é um atributo importante e discriminatório na identificação e extração de características no processo de análise de imagens, porém, como todas as técnicas, também tem particularidades que não permitem se ajustar a todos os tipos de aplicações.

Código fonte do modelo deformável RGVF

Nesta seção é apresentado o código do algoritmo RGVF (Beta), o qual continua em desenvolvimento:

%Edge segmentation in medical images using the recursive gradient vector flow deformable contours.

%Advisor: Adilson Gonzaga

clear all [X,map] = imread('04imageRM.bmp'); I = ind2gray(X,map);

%I (0 to 1)

%=====

fmin = min(I(:)); fmax = max(I(:));

I = (I - fmin) / (fmax - fmin);

```

%=====

f = I; figure, imshow(f);

%=====
%Nonlinear Diffusion Filtering
%=====

%Source Image
Image = f;

t = 50; %10 Number of iterations of diffusion
lambda = 0.2 % Parameter of edge threshold
dt = 0.05; %Time increment (0 < dt <= 0.25)

[Gy, Gx] = size(Image);

for i = 1:t;

    % Calculate gradient in all directions (N,S,E,W)
    In = [ Image(1, :); Image(1:Gy - 1, :)] - Image;
    Is = [ Image(2:Gy, :); Image(Gy, :)] - Image;
    Ie = [ Image(:, 2:Gx) Image(:, Gx)] - Image;
    Iw = [ Image(:, 1) Image(:, 1:Gx - 1)] - Image;

    % Calculate diffusion coefficients in all directions
    Cn = 1./(1 + (abs(In)/lambda).^2);
    Cs = 1./(1 + (abs(Is)/lambda).^2);
    Ce = 1./(1 + (abs(Ie)/lambda).^2);
    Cw = 1./(1 + (abs(Iw)/lambda).^2);

    Image = Image + dt * (Cn .* In + Cs .* Is + Ce .* Ie + Cw .* Iw);

```



```

    end
%=====
fmin = min(Image(:));
fmax = max(Image(:));
Image = (Image - fmin) / (fmax - fmin); %Normalize f (0 to 1)
%=====

    figure, imshow(Image); II = edge(Image,'sobel'); figure, imshow(II); f = ind2gray(II,map);
%Recursive Gradient Vector Flow field
mu = 0.05;
ITER = 20;
[fx,fy] = gradient(f);

    u = fx; v = fy; %Initialize GVF to the gradient
SqrMagf = fx .* fx + fy .* fy; %Squared magnitude of the gradient field

    %Get u,v for GVF field
for i = 1:ITER, u = u + mu * 4 * del2(u) - SqrMagf .* (u - fx);
v = v + mu * 4 * del2(v) - SqrMagf .* (v - fy);
end
%Normalizing the GVF external force
mag = sqrt(u .* u + v .* v); pxx = u ./ mag; pyy = v ./ mag;

    disp('RGVF a partir do filtro'); figure, quiver(u, v); axis off; axis equal; axis 'ij';

    disp('RGVF Field'); figure, quiver(pxx, pyy); axis off; axis equal; axis 'ij';

    %Initialize the template
disp(' Start deformation'); pause;
figure, imshow(I); axis('square', 'off'); t = 0:0.05:6.28; [xx, yy] = size(I);
x = xx / 2 + 45*cos(t); y = yy / 2 + 45*sin(t);

```

```

[x,y] = snakeinterp(x,y,3,1);

%Display deformation
hold on x = x(:); y = y(:); plot([x; x(1,1)],[y; y(1,1)],'r'); hold off

pause(1);

%Parameters:
%alpha(elasticity), beta(rigidity), gamma(viscosity),
%kappa (weight of external force)

ITER = 70;

for i = 1:ITER,
alpha = 0.05; beta = 0; gamma = 1; kappa = 0.3;
N = length(x);

alpha = alpha * ones(1, N);
beta = beta * ones(1, N);

% produce the five diagonal vectors
alpham1 = [alpha(2:N) alpha(1)];
alphap1 = [alpha(N) alpha(1:N - 1)];
betam1 = [beta(2:N) beta(1)];
betap1 = [beta(N) beta(1:N - 1)];

a = betam1;
b = - alpha - 2 * beta - 2 * betam1;
c = alpha + alphap1 + betam1 + 4 * beta + betap1;
d = - alphap1 - 2 * beta - 2 * betap1;
e = betap1;

```

```

% generate the parameters matrix
A = diag(a(1:N-2),-2) + diag(a(N-1:N),N-2);
A = A + diag(b(1:N-1),-1) + diag(b(N), N-1);
A = A + diag(c);
A = A + diag(d(1:N-1),1) + diag(d(N),-(N-1));
A = A + diag(e(1:N-2),2) + diag(e(N-1:N),-(N-2));

```

```

invAI = inv(A + gamma * diag(ones(1,N)));

```

```

% Deformable Models

```

```

vpx = interp2(pxx,x,y,'linear');
vpy = interp2(pyy,x,y,'linear');

```

```

x = invAI * (gamma * x + kappa * vpx);
y = invAI * (gamma * y + kappa * vpy);

```

```

fprintf(1, '\ %3d', i);
if (mod(i, 20) == 0)
    fprintf(1, '\ n');
end
if (mod(i, 5) == 0)
    [x,y] = snakeinterp(x,y,3,1);
    %Display deformation
    hold on
    x= x(:); y = y(:);
    plot([x;x(1,1)],[y;y(1,1)],'r');
    hold off

```

```

    pause;
end
end

```

```
cla; imshow(I); axis('square', 'off');
```

```
%Display deformation
```

```
hold on x = x(:); y = y(:);
```

```
plot([x;x(1,1)],[y;y(1,1)],'b'); hold off
```