



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

Pedro Pedrosa Rebouças Filho

**MCA Crisp: novo método de segmentação dos
pulmões em imagens de TC baseado no Método de
Contorno Ativo**

FORTALEZA – CEARÁ
FEVEREIRO 2009

Livros Grátis

<http://www.livrosgratis.com.br>

Milhares de livros grátis para download.

PEDRO PEDROSA REBOUÇAS FILHO

**MCA Crisp: novo método de segmentação dos pulmões em
imagens de TC baseado no Método de Contorno Ativo**

*Dissertação de Mestrado apresentada
à Coordenação do Curso de
Pós-Graduação em Engenharia de
Teleinformática da Universidade
Federal do Ceará como parte dos
requisitos para obtenção do grau
de Mestre em Engenharia de
Teleinformática.*

Área de Concentração: Sinais e
Sistemas

Orientador : Prof. Dr. Paulo César
Cortez

Co-orientador : Prof. Dr. Marcelo
Alcantara Holanda

FORTALEZA – CEARÁ

FEVEREIRO 2010

Resumo

Sistemas computacionais vem desempenhando papel importante em várias áreas da medicina, notadamente no auxílio ao diagnóstico médico. Neste sentido, estudos na área da Visão Computacional são realizados para desenvolver técnicas e sistemas capazes de detectar automaticamente diversas doenças. Dentre os exames existentes que permitem o auxílio ao diagnóstico e a aplicação de sistemas computacionais em conjunto, destaca-se a Tomografia Computadorizada (TC). Este exame possibilita visualizar órgãos internos, como por exemplo, o pulmão e suas estruturas. Isto é possível, devido cada estrutura do corpo humano possuir um valor específico de densidade radiológica, medido em Unidades Hounsfield (UH). Deste modo, o tomógrafo é um equipamento capaz de adquirir imagens de TC destes órgãos para que o médico possa realizar a detecção precoce ou não, bem como o acompanhamento de diversas doenças, e técnicas de análise destas imagens, podem ampliar a quantidade de informação adquirida. Para isto, são utilizadas várias técnicas com a finalidade de segmentar, reconhecer e identificar detalhes da região de interesse na imagem de TC analisada. Este trabalho centraliza seus esforços na etapa de segmentação dos pulmões, que consiste em separar o objeto a ser analisado do restante da imagem. Dentre as técnicas de segmentação que apresentam um grande potencial para o desenvolvimento de novas tecnologias, destaca-se o Método de Contorno Ativo (MCA), também conhecido como *snake*. Este método consiste em traçar uma curva inicial em torno ou dentro de um objeto de interesse. Esta curva se deforma, conforme algumas forças que atuam sobre o mesmo, deslocando-a até as bordas do objeto. Este processo é realizado por iterações sucessivas de minimização de uma dada energia, associada à curva. Dentre os MCAs citados na literatura, este trabalho analisa os MCAs Tradicional, Balão e *Gradient Vector Flow* (GVF), apresentando suas vantagens e limitações na segmentação dos pulmões em imagens

de TC. Deste modo, este trabalho propõe um MCA, denominado MCA Crisp, com inicialização automática da curva e uma nova força externa baseada em regras e nas densidades radiológicas pulmonares para segmentar os pulmões em imagens de TC. Além disso, uma comparação entre os resultados dos MCAs Tradicional, Balão, GVF e Crisp é realizada, demonstrando a superioridade do MCA Crisp na segmentação dos pulmões em imagens de TC, em relação aos outros métodos estudados. Por fim, com o intuito de validar o método proposto é feita uma análise dos resultados obtidos por este método junto a um médico especialista na área da Pneumologia do Hospital Universitário Walter Cantídio da Universidade Federal do Ceará. Nesta validação, são utilizadas 100 pulmões em imagens de TC, considerando todas as imagens analisadas, cujos resultados desta segmentação, dividida em 5 classes, são: 57% ótimas, sem falhas, 36% aceitáveis, com pequenos erros, e 7% razoáveis, com erros grosseiros, 0% ruim, segmentando apenas uma pequena parte do pulmão, e 0% péssima, obtendo uma segmentação totalmente errada. Conclui-se que o Método de Contorno Ativo Crisp é um algoritmo útil para segmentar os pulmões em imagens de TC, e é capaz de integrar sistemas que auxiliem o diagnóstico médico.

Palavras-chave: Auxílio ao diagnóstico médico, Contornos Ativos, Segmentação do pulmão, Densidade Radiográfica.

Abstract

T^{he}

Keywords: .

Dedico este trabalho a Deus e Todos Meus Irmãos Espirituais.

Agradecimientos

Não existe um caminho para a felicidade. A felicidade é o caminho.

Mahatma Gandhi

Sumário

Lista de Figuras	x
Lista de Tabelas	xi
Lista de Siglas	xi
1 INTRODUÇÃO	1
1.1 Motivação	3
1.2 Objetivos	5
1.3 Organização da Dissertação	5
2 FUNDAMENTAÇÃO TEÓRICA E ESTADO DA ARTE	6
2.1 Segmentação	6
2.1.1 Segmentação por similaridade	7
2.1.2 Segmentação por descontinuidade	9
2.2 Métodos de Contornos Ativos (MCAs)	13
2.2.1 MCA Tradicional	14
2.2.2 MCA Balão	20
2.2.3 MCA <i>Gradient Vector Flow</i>	23
2.3 Estado da Arte	27
3 METODOLOGIA	29
3.1 Aquisição de Imagens	29
3.2 Limitações dos MCAs Tradicional, Balão e GVF na segmentação dos pulmões em imagens de TC	31
3.3 Método proposto	34
3.4 Inicialização do Contorno	38
3.5 Adição e Remoção de pontos	40
4 RESULTADOS E DISCUSSÕES	42
4.1 Análise do algoritmo de inicialização	42
4.2 Análise comparativa entre os MCAs Crisp, Balão e GVF	43

4.3	Avaliação Qualitativa do Médico especialista	45
5	CONCLUSÕES, CONTRIBUIÇÕES E TRABALHOS FUTUROS	51
	Referências Bibliográficas	59

Lista de Figuras

1.1	imagens de seções do pulmão a) planos de cortes no corpo, b) seção sagital, c) seção axial e d) seção coronal, adaptada de (SLUIMER; PROKOP; GINNEKEN, 2005).	2
1.2	etapas de um sistema de Visão Computacional típico.	3
2.1	exemplo de aplicação da limiarização: a) imagem original e b) resultado (ALBUQUERQUE, 2006).	8
2.2	exemplo de aplicação da técnica de Crescimento de Região: a) imagem original com a semente em vermelho, b) resultado da segmentação em vermelho.	9
2.3	exemplo de detecção de linhas: a) imagem original e b) resultado da detecção de linhas na diagonal (GONZALEZ; WOODS, 2008).	11
2.4	exemplo de aplicação do operador Sobel: a) imagem original e b) resultado do operador Sobel (SIEGWART; NOURBAKHS, 2004).	13
2.5	exemplo dos vizinhos considerados no cálculo da energia.	16
2.6	iteração do MCA Tradicional: a) inicialização, b) a g) iterações intermediárias e h) resultado final.	20
2.7	aplicação do MCA Tradicional na segmentação de objetos côncavos: a) inicialização e b) resultado final.	21
2.8	exemplo da atuação da força balão repulsando um ponto $c(s)$ em direção contrária do baricentro $T(x_t, y_t)$	22
2.9	a) inicialização da curva, b) e c) são resultados das iterações intermediárias e d) resultado final da segmentação pelo MCA Balão.	23
2.10	aplicação do MCA Balão, desde a) inicialização da curva, b) e c) iterações intermediárias d) resultado final da segmentação.	23
2.11	a) convergência do <i>snake</i> , b) campo de vetores gradiente, c) ampliação da concavidade do campo de gradiente (Xu and Price, 1997).	24
2.12	fluxo Gradiente obtido com a) 100 iterações, b) 200 iterações, e c) 400 iterações.	25
2.13	primeira limitação do MCA Tradicional superada pelo MCA GVF: a) inicialização da curva, b) e c) iterações intermediárias d) resultado final da segmentação.	26

2.14	segunda limitação do MCA Tradicional, corrigida pelo MCA GVF: a) inicialização da curva, b) e c) iterações intermediárias e d) resultado final da segmentação pelo MCA GVF.	26
2.15	limitação dos MCAs Tradicional, Balão e GVF: a) inicialização da curva, b) e c) iterações intermediárias, e d) resultado final da segmentação pelo método GVF.	27
3.1	imagem de TC dos pulmões: a) obtida com TC multidetectora, b) representação das faixas de densidades sem ruído, c) obtida a partir da TCAR e d) representação das faixas de densidades com ruído. . .	31
3.2	exemplos de imagens de TC do pulmão nas posições: a) base obtida por TCAR, b) base obtida através de TC com multidetectores e c) ápice.	32
3.3	imagens de TC do pulmão com: a) e c) inicialização do método Balão e GVF, respectivamente, b) e d) resultado final para os respectivos métodos.	33
3.4	imagens de TC dos pulmões: a) original e b) gradiente Sobel, c) vetor de fluxo gradiente com 400 iterações.	34
3.5	imagem de TC dos pulmões: a), b) e c) originais, d), e) e f) gradiente Sobel, g), h) e i) resultado da análise realizada pela força externa do método proposto, j), l) e m) força externa do método proposto. . . .	37
3.6	demonstração das regiões utilizadas para encontrar os pontos para as inicializações da curva nos pulmões esquerdo e direito.	38
3.7	demonstração das regiões utilizadas para encontrar os pontos para as inicializações dos contornos dos pulmões esquerdo e direito, em amarelo.	40
3.8	figura para base do cálculo do ângulo entre três pontos.	41
4.1	exemplos de resultados do algoritmo de inicialização da curva em imagens de TC dos pulmões.	43
4.2	imagem de TC dos pulmões: a), b), c) d) inicialização da curva, em vermelho, resultados da segmentação aplicando e), f), g) e h) MCA Balão, i), j), l) e m) MCA GVF, n), o), p) e q) MCA Crisp.	44
4.3	exemplo de avaliação qualitativa de segmentação dos pulmões em imagens de TC: a) imagem original, b) segmentação ótima, c) segmentação aceitável, d) segmentação razoável, e) segmentação ruim e f) segmentação péssima.	46
4.4	exemplos de segmentações dos pulmões em imagens de TC pelo método proposto a nível de: a) e b) ápice, c) e d) base, e) e f) hilo. . .	48
4.5	análise de erros encontrados na segmentação do pulmão esquerdo em imagens de TC: a nível de ápice a) imagem original, b) energia crisp e balão da imagem e c) segmentação errônea; a nível de hilo d) imagem original, e) energia crisp e balão da imagem e f) segmentação errônea; a nível de base g) imagem original, h) energia crisp e balão da imagem e i) segmentação errônea.	49

Lista de Tabelas

4.1	<i>método qualitativo de avaliação de segmentação de imagens</i>	45
4.2	<i>Resumo da avaliação qualitativa da segmentação do método proposto .</i>	47

Lista de Siglas

DICOM	Imagem Digital e Comunicações em Medicina (<i>Digital Imaging and Communications in Medicine</i>)
DPOC	Doença Pulmonar Obstrutiva Crônica
MCA	Método de Contorno Ativo
OMS	Organização Mundial da Saúde
PDI	Processamento Digital de Imagens
TC	Tomografia Computadorizada
TCAR	Tomografia Computadorizada de Alta Resolução
UH	Unidades Hounsfield

Capítulo 1

INTRODUÇÃO

O desenvolvimento de sistemas computacionais aliada ao conhecimento médico, tem possibilitado a construção de equipamentos importantes quanto na identificação de doenças e acompanhamentos de seus tratamentos. O uso destes equipamentos está presente em diversas áreas da medicina, desde simples exames laboratoriais a exames de elevada complexidade, como a Tomografia Computadorizada (TC) (WEBSTER, 1998).

O exame por TC foi desenvolvido por Hounsfield e Cormack em 1973 (HOUNSFIELD, 1973; KAK; SLANEY, 1999), buscando visualizar órgãos internos, como por exemplo, o pulmão e suas estruturas. Deste modo, o tomógrafo, equipamento utilizado para realizar a TC, é capaz de adquirir imagens de TC destes órgãos para que o médico possa realizar a detecção precoce ou não, bem como o acompanhamento de diversas doenças. Além disso, técnicas de Processamento Digital de Imagens (PDI) podem ampliar a quantidade de informação adquirida neste tipo de imagem. Neste caso, em geral, reduz-se o tempo de análise dos exames e, ao mesmo tempo, aumenta-se a acurácia no diagnóstico, auxiliando o médico especialista em suas interpretações (LI; LIU; FOX, 2005).

Em uma imagem digital obtida a partir de uma TC, o valor de cada *pixel* desta imagem corresponde à atenuação da intensidade dos raios-X, expresso em Unidades Hounsfield (UH). A escala da intensidade de atenuação tem valores específicos para cada tecido ou estrutura do corpo humano, como exemplo, o tecido ósseo está entre 600 e 2000 UH. Já para o ar, esta densidade é de -1000 UH e a água de 0 UH, sendo estes dois tipos de molécula utilizados na calibração de tomógrafos (GEVENOIS;

YERNAULT, 1995; VIEIRA *et al.*, 1998). As imagens de TC podem ser adquiridas nas seções axial, sagital e coronal, conforme é mostrado na Figura 1.1.

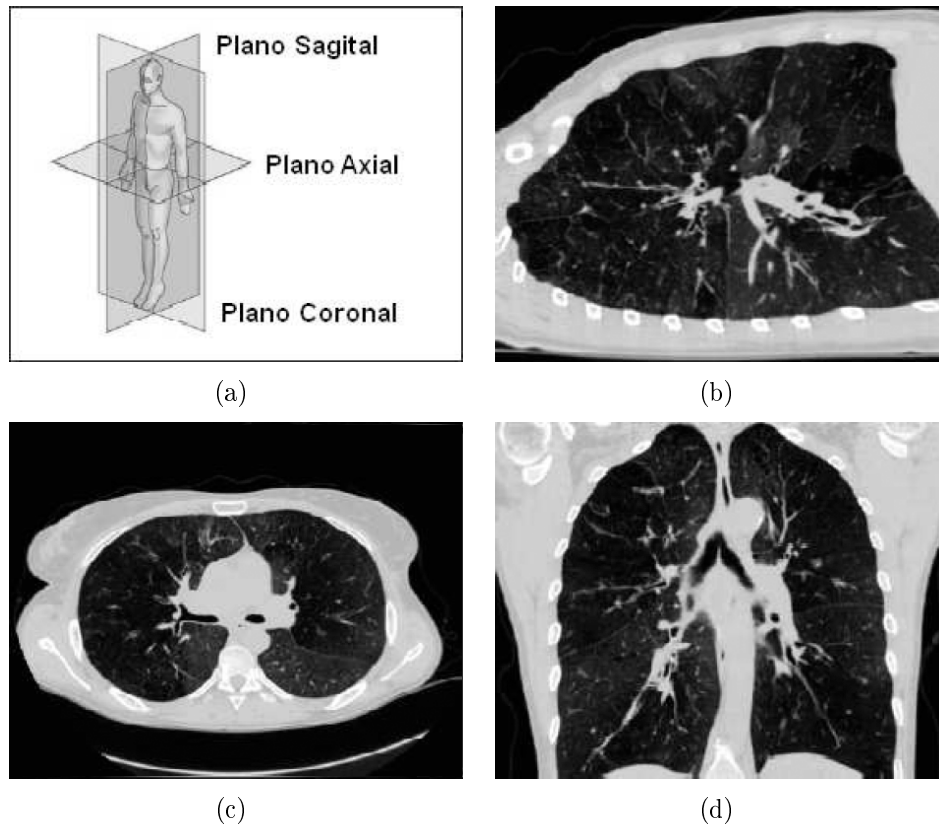


Figura 1.1: imagens de seções do pulmão a) planos de cortes no corpo, b) seção sagital, c) seção axial e d) seção coronal, adaptada de (SLUIMER; PROKOP; GINNEKEN, 2005).

As imagens obtidas em TC são utilizadas em estudos na área da Visão Computacional para desenvolver técnicas e sistemas capazes de detectar de forma automática diversas doenças. Para isto, são utilizadas vários métodos com a finalidade de segmentar, reconhecer e identificar detalhes de uma dada região de interesse na imagem analisada (CELLI; MACNEE, 2004). Estas técnicas estão distribuídas em etapas em um sistema de Visão Computacional típico, conforme é ilustrado na Figura 1.2.

A primeira etapa de um sistema de Visão computacional, a etapa de aquisição, consiste no processo de captura da imagem, enquanto a etapa de pré-processamento consiste em retirar falhas e imperfeições da imagem (ALEXANDRIA, 2005). A segmentação é a etapa responsável por dividir a imagem em regiões de interesse (GONZALEZ; WOODS, 2008). Posteriormente, a região segmentada é utilizada para

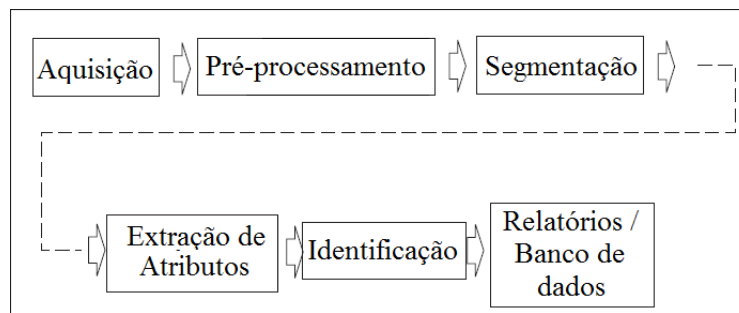


Figura 1.2: etapas de um sistema de Visão Computacional típico.

extrair atributos, utilizados para identificar padrões previamente estabelecidos. Por fim é gerado um relatório com as análises e informações obtidas (ALEXANDRIA, 2005).

Este trabalho centraliza seus esforços na etapa de segmentação, especificamente dos pulmões em imagens de TC. Dentre as técnicas de segmentação mais atuais que apresentam um grande potencial para o desenvolvimento de novas tecnologias, destaca-se o Método de Contorno Ativo (MCA), também conhecido como *snake*. Este método foi proposto em 1987 por Kass, Witkin e Terzopoulos (KASS; WITKIN; TERZOPOULOS., 1987), e permite realizar a segmentação de objetos em imagens digitais por meio de uma curva que se deforma através de informações de sua geometria e da imagem analisada.

1.1 Motivação

Diversas doenças pulmonares podem ser detectadas e acompanhadas através das imagens obtidas a partir da TC, dentre as quais destaca-se a Doença Pulmonar Obstrutiva Crônica (DPOC). Esta doença é um problema de saúde mundial de alta mortalidade, e que é muitas vezes subestimada e subdiagnosticada, levando ao subtratamento. Dentre os causadores desta doença, o tabagismo é a sua causa principal. A perspectiva para as próximas 3 décadas, segundo estimativa da Organização Mundial da Saúde (OMS), é que esta atinja mais pessoas no mundo todo, visto que a quantidade de fumantes deve ultrapassar de 1,2 bilhões para 1,6 bilhões entre 2000 e 2030. Deste modo, calcula-se que as mortes em decorrência das doenças causadas pelo tabaco devem aumentar de 4,9 milhões para 10 milhões, sendo que 70% destas devem ocorrer nos países em desenvolvimento (SILVA; DAVID, 2004; JARDIM; OLIVEIRA; NASCIMENTO, 2006).

Para prevenir, detectar e acompanhar esta e outras doenças na área da Pneumologia, é importante desenvolver ferramentas que auxiliem o diagnóstico do médico especialista, especificamente na análise de imagens de TC dos pulmões. Neste sentido, o desenvolvimento de técnicas de segmentação dos pulmões em imagens de TC acelera o processo de análise destes por um médico especialista, visto que este processo, geralmente, é realizado manualmente pelo médico.

Uma vez realizada a segmentação dos pulmões é importante para o especialista que esta seja precisa, não podendo ter erros, sejam por adição de regiões que não fazem parte dos pulmões, ou por remoção de partes destes. Tais erros podem alterar a análise do médico, resultando num diagnóstico impreciso. Há outro problema, não menos importante que a segmentação dos pulmões, que é o tempo gasto neste processo.

Neste sentido, o auxílio ao diagnóstico médico mostra-se importante, tanto do ponto de vista clínico quanto em pesquisa. Dentre os diversos fatores que contribuem para isto, pode-se citar o aumento da precisão do diagnóstico do médico especialista à medida que aumenta o número de informações a sua disposição sobre o estado do paciente. Deste modo, certas doenças podem ser detectadas precocemente, inclusive salvando vidas em alguns casos. Além disto, algumas técnicas desenvolvidas permitem que o médico especialista acompanhe o quadro clínico evolutivo da doença nos pacientes, facilitando a avaliação desta (FÉLIX, 2007).

Com base na discussão anterior, o diagnóstico auxiliado por sistemas computacionais vem ganhando mais espaço em várias modalidades diagnósticas por imagem, cuja finalidade é reduzir o tempo de avaliação dos exames e também aumentar sua acurácia, auxiliando o médico em suas interpretações (LI; LIU; FOX, 2005; DOI, 2004). Algumas doenças pulmonares, cujo diagnóstico pode ser estabelecido por exames de imagem de TC, podem ser melhor estudadas quando analisadas por sistemas computacionais especificamente desenvolvidos para este fim.

Com a finalidade de atenuar os problemas citados, é necessário desenvolver um método que possibilite uma segmentação correta, automática e precisa dos pulmões em imagens de TC.

1.2 Objetivos

O presente trabalho propõe um novo Método de Contorno Ativo capaz de segmentar automaticamente os pulmões em imagens de TC. Além disto, este trabalho possui outros objetivos específicos:

- ▶ inicializar automaticamente o contorno dentro dos pulmões;
- ▶ comparar o MCA proposto com os MCAs Balão desenvolvido por Mackiewicz (MACKIEWICH, 1995) e *Gradient Vector Flow* desenvolvido por Xu e Prince (XU; PRINCE, 1997);
- ▶ analisar a eficácia do MCA proposto juntamente com um médico especialista em imagens de TC dos pulmões.

1.3 Organização da Dissertação

No Capítulo 2 são apresentados alguns conceitos básicos de Métodos de Contornos Ativos, abordando o MCA Tradicional desenvolvido por Kass e demonstrando suas limitações. Posteriormente, são apresentados dois métodos que buscam suprir tais limitações, os MCAs Balão (MACKIEWICH, 1995) e *Gradient Vector Flow* (XU; PRINCE, 1997).

No Capítulo 3 é discutido o processo de aquisição das imagens de TC dos pulmões, e as limitações dos MCAs citados na segmentação dos pulmões em imagens de TC. Posteriormente, é apresentado um novo MCA, denominado MCA Crisp, que busca suprir as limitações encontradas pelos MCAs citados.

No Capítulo 4 são apresentados os resultados da segmentação do método proposto, comparando-os com os MCAs Balão e *Gradient Vector Flow* em imagens de pacientes com DPOC e em imagens de voluntários sadios. Posteriormente, são avaliadas por um médico especialista 100 segmentações de pulmões em imagens de TC, obtidas pelo método proposto, nos níveis ápice, hilo e base.

No Capítulo 5, por fim, são apresentadas as conclusões, contribuições finais deste trabalho e as que podem ser desenvolvidas a partir deste.

Capítulo 2

FUNDAMENTAÇÃO TEÓRICA E ESTADO DA ARTE

Neste Capítulo primeiramente é apresentado com detalhes o conceito e os tipos de segmentação de objetos em imagens digitais, bem como apresenta a teoria dos MCAs, discutindo suas vantagens e limitações. Por fim, apresenta o Estado da Arte em segmentação de imagens médicas, especialmente dos pulmões em imagens de TC.

2.1 Segmentação

A segmentação de imagens é um dos principais processos constituintes de um sistema de Visão Computacional, cujo objetivo é separar as regiões que compõem uma imagem para que seja possível a extração de atributos das mesmas. Deste modo, regiões disjuntas podem ser caracterizadas individualmente como áreas com semelhança de níveis de cinza, textura ou outra característica de interesse para aplicação. Portanto, a segmentação consiste em atribuir um rótulo a cada *pixel* da imagem, identificando a qual região este pertence, de acordo com suas propriedades (ALEXANDRIA, 2005).

De acordo com Gonzales e Woods (GONZALEZ; WOODS, 2008), as técnicas de segmentação de imagens geralmente são baseadas em duas propriedades básicas, similaridade e descontinuidade. A primeira categoria, a similaridade, baseia-se na divisão da imagem em regiões similares, cujo o critério de semelhança é estabelecido previamente. A limiarização e o crescimento de regiões são exemplos de segmentação

por similaridade. Já a descontinuidade, separa as regiões de uma imagem baseada em mudanças bruscas nos valores de *pixels* vizinhos, como a detecção de pontos, linhas e bordas na imagem.

2.1.1 Segmentação por similaridade

Segmentação por similaridade baseia-se na separação de objetos por possuírem valores próximos de uma dada características pré-estabelecida. Dentre os métodos que integram este tipo de segmentação, destaca-se a Limiarização e o Crescimento de Regiões.

Limiarização

A técnica de segmentação baseada na limiarização tem como princípio básico determinar um valor como limiar, geralmente em tom de cinza, que esteja dentro do intervalo de tonalidades da imagem, como por exemplo, uma imagem com resolução de 8 *bits*, o limiar pode estar entre 0 e 255.

Após estabelecer os limiares de cada região da imagem, é possível rotular cada *pixel*, associando-o a faixa de valores estabelecido em cada região. Quando só existe duas regiões para classificação, uma destas regiões recebe rótulo 0 e a outra região recebe rótulo 1, sendo esta técnica, neste caso, denominada de binarização. Deste modo, a operação que resulta em uma imagem binarizada $B(x, y)$, aplicando um limiar fixo L em uma imagem $I(x, y)$ é definida pela equação (GONZALEZ; WOODS, 2008)

$$B(x, y) = \begin{cases} 1, & \text{se } I(x, y) > L \\ 0, & \text{caso contrário.} \end{cases} \quad (2.1)$$

Um exemplo da aplicação da binarização em uma imagem digital é apresentado na Figura 2.1, em que o tom de cinza da imagem está na faixa de 0-255, e o limiar fixo utilizado é 127.

Em uma mesma imagem pode também ser estabelecido mais de um limiar, técnica esta denominada de multi-limiarização (ZAHARA; FAN; TSAI, 2005; PAPAMARKOS; STROUTHOPOULOS; ANDREADIS, 2000). Esta técnica subdivide a imagem em mais de duas regiões, estabelecendo os limites inferior e superior de cada região de interesse. Um exemplo de aplicação desta técnica, utilizando três




Figura 2.1: exemplo de aplicação da limiarização: a) imagem original e b) resultado (ALBUQUERQUE, 2006).

regiões é

$$R(x, y) = \begin{cases} 0, & \text{para } 0 < I(x, y) < 86 \\ 1, & \text{para } 85 < I(x, y) < 171 \\ 2, & \text{para } 170 < I(x, y) < 256 \end{cases} \quad (2.2)$$

em que $R(x, y)$ classifica cada *pixel* da imagem por um índice i , determinado pelos limiares inferior e superior de cada região, assumindo valor 0 para intensidades de tom de cinza na faixa 0-85, 1 para a faixa 86-170 e 2 para a faixa 171-255.

As técnica de limiarização possui a limitação de ser dependente do valor de limiar definido, gerando resultados insatisfatórios quando as imagens possuem ruídos, imperfeições ou mudanças na tonalidade dos objetos de interesse. Neste sentido, diversos trabalhos propõem técnicas para encontrar valores ótimos de limiar (BERNSEN, 1986; COCQUEREZ; PHILLIP, 1995; JOHANNSEN; BILLE, 1982), porém estes obtêm resultados satisfatórios apenas em aplicações específicas. Além disto, ao aplicar esta técnica em uma imagem que possui mais de um objeto de interesse, é necessário utilizar outras técnicas para identificá-los, pois o uso exclusivo da técnica de limiarização não faz distinção entre tais objetos.

Crescimento de Região

O Crescimento de Região (CR) é uma técnica de segmentação de imagens usadas para unir as regiões de interesse. Esta técnica realiza o agrupamento de subgrupos ou grupos de *pixels* em uma região desejada. Isto é possível através da expansão de uma dada região que é inicializada por um *pixel*, denominado semente. Esta

expansão ocorre pela agregação de *pixels* à região por iterações sucessivas de análise da vizinhança de uma dada região (GONZALEZ; WOODS, 2008).

Para um *pixel* ser agregado à região é necessário que este esteja na vizinhança da região e que obedeça um critério pré-estabelecido. Este, geralmente, baseia-se em parâmetros, como intensidade de tom de cinza, média de tom de cinza na região, entre outros.

Um exemplo de aplicação desta técnica é apresentada na Figura 2.2, em que a semente é mostrada em vermelho na Figura 2.2(a) e a regra de agrupamento é que a tonalidade de cinza seja igual à tonalidade da semente escolhida, resultando na segmentação apresentada na Figura 2.2(b).




Figura 2.2: exemplo de aplicação da técnica de Crescimento de Região: a) imagem original com a semente em vermelho, b) resultado da segmentação em vermelho.

A eficácia deste método depende diretamente da escolha da semente e da regra de adesão. Caso essas escolhas não sejam adequadas, a segmentação apresentará falhas.

2.1.2 Segmentação por descontinuidade

As técnicas de segmentação de imagens baseadas na detecção de mudanças bruscas entre *pixels* vizinhos na imagem, são responsáveis pela detecção de: pontos, linhas e bordas. O resultado R da detecção de cada um destes métodos podem ser obtidos por uma convolução bidimensional dada por

$$R = M_{3 \times 3} * I_{l \times c}, \quad (2.3)$$

em que $I_{l \times c}$ é a imagem analisada com largura l e colunas c determinadas em números de *pixels*, $*$ o operador convolução e $M_{3 \times 3}$ é uma matriz com dimensão 3×3 determinada por

$$M = \begin{bmatrix} w_1 & w_2 & w_3 \\ w_4 & w_5 & w_6 \\ w_7 & w_8 & w_9 \end{bmatrix}, \quad (2.4)$$

em que os termos w_i são pesos específicos para cada detecção.

Detecção de pontos

A detecção de pontos parte do seguinte princípio: pontos somente estão presentes em regiões homogêneas ou perto delas. Deste modo, um ponto é detectado quantificando a diferença deste ponto para seus vizinhos, determinado utilizando a equação 2.4 aplicando a máscara M dada por (GONZALEZ; WOODS, 2008)

$$M = \begin{bmatrix} -1 & -1 & -1 \\ -1 & 8 & -1 \\ -1 & -1 & -1 \end{bmatrix}, \quad (2.5)$$

em que o resultado R obtido aplicando esta máscara na equação 2.3 deve ser maior do que um dado limiar L para evitar detecção de ruídos ou imperfeições na imagem. Este limiar é arbitrário e depende da imagem em análise.

Detecção de linhas

O princípio da detecção de linhas se assemelha com a detecção de pontos, devido as linhas se destacarem em regiões homogêneas, porém linhas possuem orientação, e o resultado da convolução pode ser horizontal H , vertical V ou na diagonal com ângulo de 45° ou -45° , resultando em D_1 e D_2 , respectivamente. Deste modo, cada orientação é detectada através de uma máscara específica baseada nas informações da linha, como por exemplo (GONZALEZ; WOODS, 2008)

$$H = \begin{bmatrix} -1 & -1 & -1 \\ 2 & 2 & 2 \\ -1 & -1 & -1 \end{bmatrix}, \quad V = \begin{bmatrix} -1 & 2 & -1 \\ -1 & 2 & -1 \\ -1 & 2 & -1 \end{bmatrix},$$

$$D_1 = \begin{bmatrix} -1 & -1 & 2 \\ -1 & 2 & -1 \\ 2 & -1 & -1 \end{bmatrix}, \quad D_2 = \begin{bmatrix} 2 & -1 & -1 \\ -1 & 2 & -1 \\ -1 & -1 & 2 \end{bmatrix}.$$

Um exemplo de detecção de linhas é apresentado na Figura 2.3, em que apenas os resultados de D_1 e D_2 são considerados. Deste modo, percebe-se na Figura 2.3(b) que as linhas verticais e horizontais da imagem não são detectadas.




Figura 2.3: exemplo de detecção de linhas: a) imagem original e b) resultado da detecção de linhas na diagonal (GONZALEZ; WOODS, 2008).

Detecção de bordas

Dentre as formas de detectar as bordas de objetos em imagens, destaca-se a utilização de operadores gradiente na imagem, podendo serem citados os operadores de Roberts, Prewitt e Sobel, considerados variações do operador gradiente (SIEGWART; NOURBAKHS, 2004). Uma forma de implementar estes operadores é aplicar uma convolução bidimensional na imagem utilizando máscaras específicas, dadas por (GONZALEZ; WOODS, 2008)

► Roberts

$$g(x, y) \cong \sqrt{(r_1^2 + r_2^2)}; \quad (2.6)$$

em que

$$r_1 = \begin{bmatrix} -1 & 0 \\ 0 & 1 \end{bmatrix}; r_2 = \begin{bmatrix} 0 & -1 \\ 1 & 0 \end{bmatrix}. \quad (2.7)$$

► Prewitt

$$g(x, y) \cong \sqrt{(p_1^2 + p_2^2)}; \quad (2.8)$$

em que

$$p_1 = \begin{bmatrix} -1 & -1 & -1 \\ 0 & 0 & 0 \\ 1 & 1 & 1 \end{bmatrix}; p_2 = \begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix}. \quad (2.9)$$

► Sobel

$$g(x, y) \cong \sqrt{(s_1^2 + s_2^2)}; \quad (2.10)$$

em que

$$s_1 = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix}; s_2 = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}. \quad (2.11)$$

Um exemplo de aplicação de um operador gradiente está ilustrado na Figura 2.4(b), em que a imagem original é apresentada na Figura 2.4(a).

Estas técnicas de detecção de bordas são muitas vezes agregadas à outras, gerando novos métodos de segmentação de imagens baseados nos critérios de descontinuidade. Dentre estes, destaca-se o Método de Contorno Ativo.




Figura 2.4: exemplo de aplicação do operador Sobel: a) imagem original e b) resultado do operador Sobel (SIEGWART; NOURBAKHS, 2004).

2.2 Métodos de Contornos Ativos (MCAs)

Diversos estudos são realizados sobre segmentação em imagens digitais, buscando suprir as limitações de cada método em aplicações específicas. Deste modo, técnicas existentes são aperfeiçoadas desenvolvendo assim novos métodos.

Neste contexto, o MCA, também chamado de *snake*, foi introduzido em 1987 por Kass, Witkin e Terzopoulos (KASS; WITKIN; TERZOPOULOS., 1987). Este método permite realizar a segmentação de objetos em imagens digitais por meio da detecção de bordas obtidas por informações da imagem, como exemplo, a intensidade dos níveis de cinza, superando as técnicas tradicionais, até então desenvolvidas.

Inicialmente este método foi aplicado na detecção de objetos em geral, principalmente nas aplicações de segmentação de bordas, detecção de movimento e utilização em visão estéreo (KASS; WITKIN; TERZOPOULOS., 1987; TERZOPOULOS *et al.*, 1987). Posteriormente, é aplicado para resolver diversos problemas de Visão Computacional, abrangendo diversas áreas como: Segurança (LOPES, 2003), Materiais para Construção Mecânica (COSTA, 2008; ALBUQUERQUE; TAVARES; FILHO, 2008), auxílio ao diagnóstico médico (ITAI; KIM; ISHIKAWA, 2007), Reconhecimento de Padrões (CHEN *et al.*, 2006), entre outros.

O MCA consiste em traçar uma curva inicial em torno ou dentro de um objeto de interesse. Esta curva se deforma, conforme algumas forças que atuam sobre o mesmo, deslocando-o até as bordas do objeto. Este processo é realizado por iterações sucessivas de minimização de uma dada energia, associada à curva. De acordo com Souza Júnior (JÚNIOR, 2006), a curva se comporta como uma fita elástica que, uma

vez solta em volta de um objeto, molda sua forma para melhor se adaptar a este.

De acordo com Kass (KASS; WITKIN; TERZOPOULOS., 1987), existem dois tipos básicos de classificação para os métodos de detecção de bordas: alto nível e baixo nível. São considerados de alto nível os métodos que possibilitam vários resultados, no qual a resposta do processo possui mais de uma solução, enquanto os de baixo nível possuem apenas uma solução para o problema de detecção de bordas. Deste modo, o MCA é dito de alto nível, possuindo a vantagem de gerar várias soluções finais, possibilitando que, a cada nova iteração, defeitos e imperfeições sejam corrigidos, enquanto os métodos de detecção de baixo nível são ditos irreversíveis.

Segundo Pichumani (PICHUMANI, 1997), as vantagens da utilização de MCA para a segmentação de imagens digitais são:

- ▶ facilidade de manipulação, pois, as forças externas se comportam de uma forma intuitiva;
- ▶ autonomia e auto-adaptação na busca pelo estado de menor energia;
- ▶ baixa sensibilidade ao ruído.

Dentre os MCAs, primeiramente é analisado neste trabalho o método Tradicional, detalhando suas forças internas e externas, discutindo sobre suas vantagens e limitações. Posteriormente, são abordados métodos que surgiram buscando soluções para as limitações deste método.

2.2.1 MCA Tradicional

Os contornos ativos são baseados em métodos variacionais, considerados modelos deformáveis, em que os pontos da curva são atualizados a cada nova iteração (BOUHOURS, 2006). Este modelo é chamado deformável porque está descrito por uma função de energia E que varia por (KASS; WITKIN; TERZOPOULOS., 1987)

$$E = \int_0^1 E_{int}[c(s)] + E_{ext}[c(s)] ds, \quad (2.12)$$

em que o termo E_{int} representa as energias internas da curva, E_{ext} o termo da energia associado com as energias externas e c a curva, sendo que sua parametrização

geométrica 2D é dada por (KASS; WITKIN; TERZOPOULOS., 1987)

$$\begin{cases} [0, 1] & \rightarrow \mathbb{R}^2 \\ s & \rightarrow c(s) = [x(s), y(s)], \end{cases} \quad (2.13)$$

no qual a posição de cada ponto $c(s)$ na imagem é determinada pelas coordenadas $x(s)$ e $y(s)$. Uma discretização da equação 2.12 permite definir a energia da curva como

$$E = \sum (E_{int} + E_{ext}), \quad (2.14)$$

em que E_{int} e E_{ext} são as energias interna e externa da curva, respectivamente.

A energia interna é proveniente das forças internas da curva, relativa apenas à geometria desta, relacionada com sua forma e a posição de seus pontos (KASS; WITKIN; TERZOPOULOS., 1987; ITAI *et al.*, 2005). Já a energia externa é proveniente das características da imagem e está associada às informações obtidas a partir desta (KASS; WITKIN; TERZOPOULOS., 1987).

O objetivo do MCA é minimizar uma função que representa a energia E da curva, que é realizado atraindo ou repulsando a curva, deslocando-a até as bordas do objeto. Este processo é realizado por iterações sucessivas e, a cada iteração, a curva é atualizado ponto-a-ponto, através de uma minimização local de energia. Isto é possível analisando a vizinhança de cada ponto, calculando as energia envolvidas e movendo-o para a coordenada que possuir a menor energia total E na vizinhança (AMINI; WEYMOUTH; JAIN, 1990).

Neste sentido, tem-se que quanto maior a vizinhança analisada, maior a quantidade de soluções possíveis, porém maior a complexidade do algoritmo e seu tempo de processamento. Um exemplo de vizinhança é ilustrado na Figura 2.5, em que é mostrada a análise dos 8 vizinhos de um ponto $c(s)$.

Energia Interna

A energia interna (E_{int}) da curva c , depende somente de sua forma e da localização de seus pontos, possuindo como um de seus principais objetivos, deformar a curva e manter a suavidade desta (SILVA, 2005).

No modelo Tradicional (KASS; WITKIN; TERZOPOULOS., 1987), o termo E_{int} da




Figura 2.5: exemplo dos vizinhos considerados no cálculo da energia.

equação 2.12, é dividido em dois termos, conhecidos como forças internas, conforme

$$E_{\text{int}}[c(s)] = \alpha(s) \left| \frac{d}{ds} c(s) \right|^2 + \beta(s) \left| \frac{d^2}{ds^2} c(s) \right|^2, \quad (2.15)$$

em que $\alpha(s)$ e $\beta(s)$ determinam a relevância de cada parcela da energia interna do ponto $c(s)$ (KASS; WITKIN; TERZOPOULOS., 1987). O primeiro termo, $\left| \frac{d}{ds} c(s) \right|^2$ desta equação, é a força ligada à elasticidade da curva ou resistência ao se esticar, denominada de Força de Elasticidade ou de Força de Continuidade. Esta força define a capacidade de um ponto da curva se distanciar ou se aproximar dos pontos vizinhos, atuando na curva deixando-o uniformemente espaçado (BOUHOURS, 2006; JÚNIOR, 2006).

O segundo termo, $\left| \frac{d^2}{ds^2} c(s) \right|^2$ da equação 2.15, é a Força de Curvatura. Esta é baseada nos ângulos internos da curva e tende a deixá-la contínua para mantê-la suave, em detrimento de trechos irregulares e pontiagudos (JÚNIOR, 2006). Deste modo, favorecendo o coeficiente $\beta(s)$ durante a fase de minimização da energia da curva, esta é forçada a perder a sua curvatura, minimizando sua área interna (BOUHOURS, 2006).

Energia Externa

A energia externa é totalmente obtida a partir de informações da imagem, possuindo diversas formas para sua definição. Alguns autores consideram as

informações referentes aos níveis de cinza dos *pixels*, outros consideram as bordas dos objetos da imagem, entre outros.

Para extrair falhas, imperfeições ou ruídos, técnicas de pré-processamento podem ser aplicadas antes do cálculo da energia externa (CARO *et al.*, 2003; BOUHOURS, 2006). Um exemplo disso é a utilização do filtro gaussiano que produz uma imagem suavizada J a partir de uma imagem I da forma

$$J = G_\sigma * I \quad (2.16)$$

em que G_σ é uma gaussiana e $*$ é o operador convolução.

Segundo Sonka (SONKA; HLAVAC; BOYLE, 2008) e Nixon e Aguado (NIXON; AGUADO, 2002) a energia externa é composta por

$$E_{\text{externa}}(V_i) = w_{\text{line}}E_{\text{line}}(V_i) + w_{\text{grad}}E_{\text{grad}}(V_i) + w_{\text{term}}E_{\text{term}}(V_i), \quad (2.17)$$

em que a energia E_{line} considera a energia proveniente das linhas, E_{grad} considera o gradiente da imagem e E_{term} é a energia relativa às terminações. Os termos w_{line} , w_{grad} e w_{term} são os pesos que determinam a importância de cada um na energia externa total.

Para Nixon e Aguado (NIXON; AGUADO, 2002), o resultado de um operador gradiente, como o operador Sobel, na imagem já extrai informações de linhas, terminações e bordas dos objetos, podendo este ser utilizado como energia externa. Deste modo, o cálculo da energia externa é otimizado, sendo calculado apenas uma componente que já possui as três informações necessárias.

MCA *Greedy*

O algoritmo MCA *Greedy* utiliza a definição de Kass (KASS; WITKIN; TERZOPOULOS., 1987) para implementar o MCA Tradicional, deste modo inserindo a equação 2.15 na equação 2.12, tem-se (KASS; WITKIN; TERZOPOULOS., 1987)

$$E[c(s)] = \alpha(s) \left| \frac{dc(s)}{ds} \right|^2 + \beta(s) \left| \frac{d^2c(s)}{ds^2} \right|^2 + \gamma(s)E_{\text{ext}}[c(s)], \quad (2.18)$$

em que $\alpha(s)$, $\beta(s)$ e $\gamma(s)$ são os pesos relativos de cada uma das componentes da energia total $E(s)$.

A primeira derivada da equação 2.18, representada pelo termo $\left| \frac{dc(s)}{ds} \right|$, é denominada de Força de Continuidade F_{cont} . A implementação desta força é realizada pela aproximação desenvolvida por Euler-Langrage. Assim, assumindo que F_{cont} é determinada por $\left| \frac{dc(s)}{ds} \right|$ e aplicando a aproximação de Euler-Langrage, tem-se (KASS; WITKIN; TERZOPOULOS., 1987)

$$\left| \frac{dc(s)}{ds} \right|^2 \approx |c(s) - c(s-1)|^2 = [x(s) - x(s-1)]^2 + [y(s) - y(s-1)]^2, \quad (2.19)$$

em que $x(s)$ e $y(s)$ são as coordenadas de cada ponto da curva c (NIXON; AGUADO, 2002). Sendo assim, pode-se descrever F_{cont} como a diferença espacial entre dois pontos consecutivos da curva c , associando-a à distância euclidiana entre dois pontos da curva

$$F_{cont} = \sqrt{[x(s) - x(s-1)]^2 + [y(s) - y(s-1)]^2}. \quad (2.20)$$

Neste contexto, a força associada à distância surge para manter o espaçamento entre os pontos da curva uniformes. A distância média DM , entre os pontos da curva, deve ser considerada para calcular esta força, visto que esta tende a espaçar igualmente os pontos. Deste modo, DM pode ser calculado por (MELO, 2005)

$$DM = \frac{\sum_{i=0}^{N-1} \sqrt{(x_i - x_{i-1})^2 + (y_i - y_{i-1})^2}}{N}, \quad (2.21)$$

em que N é a quantidade máxima de pontos e i é o índice de ordenação do ponto na curva. Então, inserindo DM no cálculo de F_{cont} , tem-se

$$F_{cont} = \left| DM - \sqrt{[x(s) - x(s-1)]^2 + [y(s) - y(s-1)]^2} \right|. \quad (2.22)$$

Esta outra formulação tende a deixar a curva igualmente espaçada, aproximando os pontos afastados e distanciando os pontos próximos, tendendo a deixar os pontos o mais equidistante possível.

A segunda derivada da equação 2.18 para cálculo das energias internas, representada pelo termo $\left| \frac{d^2v(s)}{ds^2} \right|$, denominada de Força de Curvatura F_{curv} , pode ser aproximado analogamente através da aproximação de Euler-Langrage por (NIXON;

AGUADO, 2002)

$$\left| \frac{d^2v(s)}{ds^2} \right|^2 \approx |c(s-1) - 2c(s) + c(s+1)|^2, \quad (2.23)$$

resultando em

$$F_{curv} = \sqrt{[x(s-1) - 2x(s) + x(s+1)]^2 + [y(s-1) - 2y(s) + y(s+1)]^2}. \quad (2.24)$$

Percebe-se que, para o cálculo desta energia, é usado os seus dois vizinhos imediatos, $c(s-1)$ e $c(s+1)$. Deste modo, é possível calcular uma estimativa de curvatura do ponto $c(s)$ e de sua vizinhança, no qual esta energia tende a minimizar a curvatura entre 3 pontos consecutivos $c(s-1)$, $c(s)$ e $c(s+1)$ (NIXON; AGUADO, 2002).

Por fim, a energia externa E_{ext} é determinada pelo gradiente da imagem, geralmente utilizando o operador Sobel, visto que este é simétrico e que é muito utilizado na literatura, obtendo resultados satisfatórios em diversas aplicações (MELO, 2005; BOUHOURS, 2006; JÚNIOR, 2006).

Limitações do MCA Tradicional

Os MCAs são projetados para serem modelos iterativos, em que a imagem se altera ao longo do tempo (KASS; WITKIN; TERZOPOULOS., 1987). Em aplicações não iterativas (imagens estáticas), a curva deve ser inicializada em local próximo à estrutura de interesse para garantir um bom desempenho (SOUZA, 2003; LV; GAO; ZOU, 2008).

A parametrização da energia interna do MCA Tradicional pode limitar sua flexibilidade, impedindo a representação de regiões com formas côncavas e convexas (MCINERNEY; TERZOPOULOS, 1996; BOUHOURS, 2006). Além disso, a topologia da estrutura de interesse deve ser previamente conhecida, pois, este modelo, é incapaz de executar alterações em sua topologia sem processamento adicional (MCINERNEY; TERZOPOULOS, 1996).

Um exemplo de falha relativa ao erro de inicialização da curva é mostrado na Figura 2.6. Sabendo que da Figura 2.6(a) até a Figura 2.6(h) apresenta um sequência de iterações de minimização da energia do MCA Tradicional, percebe-se que a área interna da curva diminui a cada iteração até entrar em colapso em um único ponto, conforme é mostrado na Figura 2.6(h) (JÚNIOR, 2006). Isto ocorre devido ao fato de que, em regiões homogêneas da imagem, o valor do gradiente ser nulo, fazendo a curva ser orientada apenas pelas energias internas, tendendo a deixá-la igualmente

espaçada e a minimizar sua área interna, resultando em seu colapso em um único ponto.

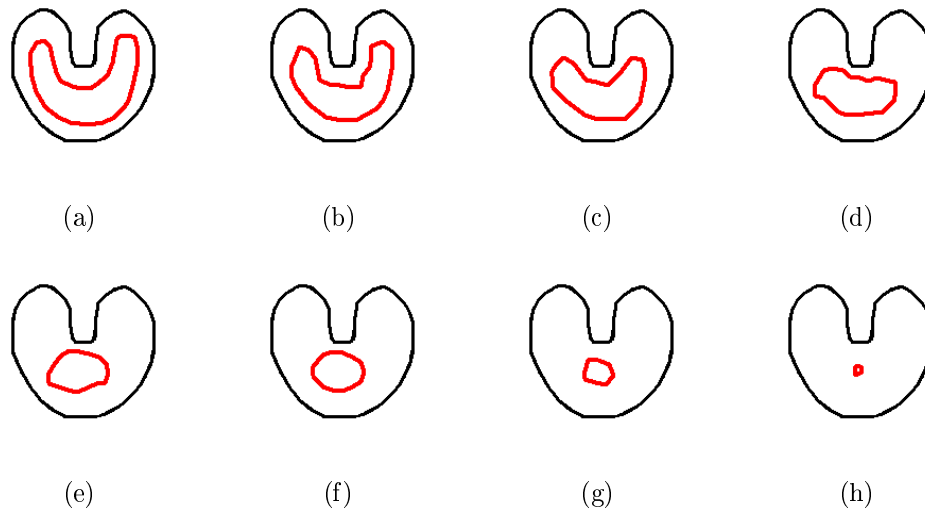


Figura 2.6: iteração do MCA Tradicional: a) inicialização, b) a g) iterações intermediárias e h) resultado final.

A outra limitação do MCA Tradicional é a ineficácia do método na segmentação de regiões côncavas ou com bifurcação, conforme é ilustrado na Figura 2.7(b), em que a inicialização é apresentada, em vermelho na Figura 2.7(a). Para entender esta limitação, é necessário analisar as energias envolvidas separadamente. A energia externa não possui informação em regiões côncavas, pois as bordas do objeto estão afastadas da curva. Já na energia interna, a Força de Continuidade tende a espaçar igualmente a curva que, ao entrar nas concavidades, aumenta seu espaçamento, sem deixá-la uniforme, e a Força de Curvatura tende a minimizar os ângulos entre pontos, que aumentam ao entrar em regiões côncavas. Deste modo, a curva não se aproxima das concavidades.

Para superar tais limitações, algumas técnicas de Processamento Digital de Imagens (PDI) são adicionados ao MCA Tradicional, gerando outros métodos, dentre os quais, este trabalho se concentra: MCA Balão e MCA *Gradient Vector Flow* (GVF).

2.2.2 MCA Balão

Com base na análise realizada anteriormente, o MCA Tradicional não detecta a borda da imagem quando é inicializado longe desta, principalmente quando




Figura 2.7: aplicação do MCA Tradicional na segmentação de objetos côncavos: a) inicialização e b) resultado final.

inicializado dentro do objeto de interesse. Isto acontece quando a borda não está presente na zona determinada pela vizinhança de cada ponto, então a curva minimiza sua energia de forma errônea, sem detectar as bordas.

Para solucionar a restrição apresentada, Cohen (COHEN, 1991) define uma outra força interna para o MCA Balão. Nesta abordagem, a energia externa se mantém igual ao MCA Tradicional, enquanto que a energia interna é definida como sendo a soma da Força de Continuidade e da Força Balão. A energia interna é então definida por

$$E_{int}[c(s)] = w_{cont}F_{cont}[c(s)] + w_{bal}F_{bal}[c(s)]. \quad (2.25)$$

em que $F_{cont}[c(s)]$ é a mesma Força de Continuidade utilizada no MCA Tradicional, $F_{bal}[c(s)]$ é a Força Balão e os parâmetros w_{cont} e w_{bal} são pesos. Estes pesos são utilizados para ajustar a importância de cada um destes no cálculo da energia interna E_{int} .

A Força Balão surge devido ao fato de que, quando a inicialização da curva é realizada dentro objeto e afastada das bordas, a curva tende a minimizar sua energia se afastando das bordas, que é o contrário do desejado. Deste modo, a Força Balão deforma a curva para este se aproximar das bordas, inflando a curva e aumentando sua área interna, sendo que a energia externa o faz parar ao detectar as bordas do objeto de interesse.

Dentre as formas de implementação da Força Balão F_{bal} , Mackiewicz (MACKIEWICH, 1995) sugere uma que se baseia no centróide da curva. Considerando este centróide como o ponto central da curva, calculado por meio da média das coordenadas x e y de todos os pontos, a Força Balão atua como uma força elástica, afastando a curva do centróide. Na Figura 2.8 é ilustrada a Força Balão atuando no

ponto $c(s)$ repulsando-o em direção oposta ao centróide T .




Figura 2.8: exemplo da atuação da força balão repulsando um ponto $c(s)$ em direção contrária do baricentro $T(x_t, y_t)$.

Numericamente, a Força Balão é determinada por (MACKIEWICH, 1995)

$$F_{bal}[c(s)] = \sqrt{E_x^2 + E_y^2}, \quad (2.26)$$

em que as componentes E_x e E_y são definidas por

$$E_x = x(s) - \left| \frac{x_t - x(s)}{x_{max}} \right|, \quad (2.27)$$

e

$$E_y = y(s) - \left| \frac{y_t - y(s)}{y_{max}} \right|, \quad (2.28)$$

em que $x(s)$ e $y(s)$ são as coordenadas do ponto $c(s)$ onde F_{bal} está sendo calculada, x_t e y_t são as coordenada do centróide T , x_{max} e y_{max} são as máximas distâncias entre um ponto da curva c e o centróide T nos eixos das abscissas e das ordenadas, respectivamente.

Para analisar os resultados do MCA Balão são utilizados duas inicializações dentro do objeto de interesse, uma centralizada e outra descentralizada. Na inicialização centralizada, obtém-se resultados satisfatórios de segmentação, conforme pode ser visto na Figura 2.9, em que a inicialização é mostrada na Figura 2.9(a).

Já quando a inicialização é descentralizada em imagens com concavidades, conforme é apresentado na Figura 2.10(a), obtém-se resultados inadequados de segmentação, demonstrado por um retângulo azul, na Figura 2.10(d). Sabendo que a curva se expande utilizando uma direção baseada entre o ponto e o centróide,




Figura 2.9: a) inicialização da curva, b) e c) são resultados das iterações intermediárias e d) resultado final da segmentação pelo MCA Balão.

é constatado que nas regiões com concavidade, os pontos que se direcionam para a região não segmentada, param na barreira gerada pela concavidade, logo a curva não atinge esta região.




Figura 2.10: aplicação do MCA Balão, desde a) inicialização da curva, b) e c) iterações intermediárias d) resultado final da segmentação.

Analisando as Figuras 2.9 e 2.10, percebe-se que este método elimina diversas limitações do método Tradicional, porém dependendo da inicialização, o problema da segmentação das concavidades continua.

2.2.3 MCA *Gradient Vector Flow*

Os principais problemas no uso do gradiente da imagem como uma força externa no MCA são (XU; PRINCE, 1997):

- ▶ o fluxo de gradiente é presente somente nas bordas, sendo nulo em regiões uniformes, conforme Figura 2.11(b);
- ▶ em regiões côncavas, ao calcular o gradiente, as bordas da concavidade se anulam, propiciando uma ausência de fluxo de gradiente nestas regiões, impossibilitando a segmentação destas, conforme é mostrado na Figura 2.11(a).




Figura 2.11: a) convergência do *snake*, b) campo de vetores gradiente, c) ampliação da concavidade do campo de gradiente (Xu and Prince, 1997).

De acordo com Chenyang Xu e Jerry L. Prince (XU; PRINCE, 1997), o MCA *Gradient Vector Flow* (GVF), soluciona os problemas de inicialização e da segmentação de concavidades, baseando-se na expansão do fluxo gradiente de uma imagem. Neste método, é construído um campo de vetores que direciona o gradiente para as bordas da imagem, conduzindo a curva até às bordas do objeto. Isto resolve os problemas de inicialização e de convergência inadequada nas concavidades (XU; PRINCE, 1997).

De acordo com Xu e Prince (XU; PRINCE, 1997), a energia deste MCA é dada pela equação

$$\alpha(s) \left| \frac{dc(s)}{ds} \right|^2 + \beta(s) \left| \frac{d^2c(s)}{ds^2} \right|^2 + E_{ext}[c(s)] = 0. \quad (2.29)$$

em que as energias internas $\left| \frac{dc(s)}{ds} \right|^2$ e $\left| \frac{d^2c(s)}{ds^2} \right|^2$ são as mesmas do MCA Tradicional, sendo $\alpha(s)$ e $\beta(s)$ seus respectivos pesos. Já a energia externa E_{ext} é definida por um fluxo de vetores gradiente w de acordo com (XU; PRINCE, 1997)

$$E_{ext} = w(x, y), \quad (2.30)$$

sendo

$$w(x, y) = [u(x, y), v(x, y)]. \quad (2.31)$$

em que $u(x, y)$ e $v(x, y)$ são funções que calculam o valor de derivadas parciais para compor $w(x, y)$. Esta energia externa é uma expansão do mapa das bordas da imagem determinada por um operador gradiente. Esta expansão é feita de forma

iterativa minimizando a energia funcional ε definida por (XU; PRINCE, 1997)

$$\varepsilon = \int \int \left\{ \mu \left(\frac{\partial u^2}{\partial x} + \frac{\partial u^2}{\partial y} + \frac{\partial v^2}{\partial x} + \frac{\partial v^2}{\partial y} \right) + |\nabla f|^2 |w - \nabla f|^2 \right\} dx dy, \quad (2.32)$$

em que $\frac{\partial u}{\partial x}$, $\frac{\partial u}{\partial y}$ e $\frac{\partial v}{\partial x}$, $\frac{\partial v}{\partial y}$ são as derivadas parciais de u e v em relação a x e y , respectivamente. Neste caso, o parâmetro μ permite ajustar o equilíbrio entre os dois termos da integral.

É observado que, quando $|\nabla f|$ é pequeno na equação 2.32, *i.e.*, em regiões homogêneas, a energia obtida provem das derivadas parciais do fluxo de vetores, resultando em um campo com pequenas variações. Por outro lado, quando $|\nabla f|$ é grande, a minimização resulta em $w = \nabla f$. Assim, obtém-se o efeito esperado para o campo, que é de manter o valor do gradiente nas bordas, e de ser pouco variável em regiões homogêneas.

Outro aspecto importante, é que o campo de Fluxo Gradiente em uma imagem depende diretamente da parametrização do fator μ da equação 2.32 e do número de iterações da aplicação desta mesma equação na imagem. O valor ótimo do fator μ sugerido por Bouhours (BOUHOURS, 2006) é 0,1. Sendo assim, aplicando a equação 2.32 em uma imagem com 100, 200 e 400 iterações, conforme ilustrado na Figura 2.12, constata-se que a área ocupada pelo fluxo de vetores gradiente aumenta proporcionalmente ao número de iterações.

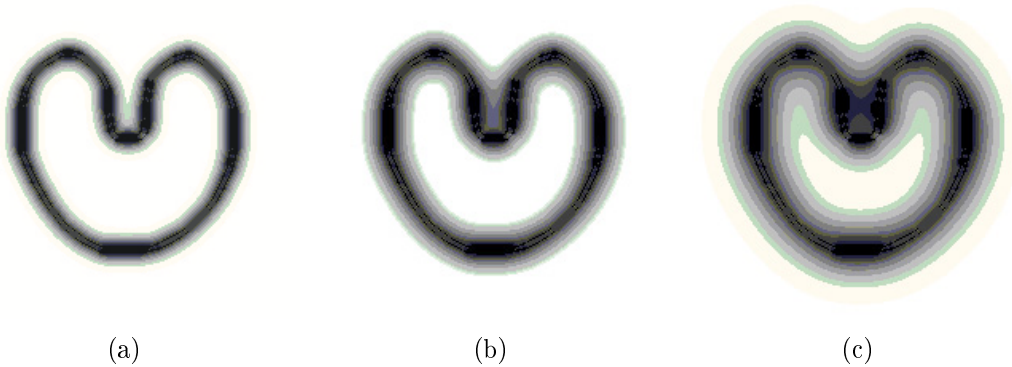


Figura 2.12: fluxo Gradiente obtido com a) 100 iterações, b) 200 iterações, e c) 400 iterações.

A MCA GVF é avaliado neste trabalho utilizando as limitações encontradas nos MCAs Tradicional e Balão, utilizando três inicializações diferentes: fora do objeto com concavidades, dentro do objeto afastado das bordas e dentro do objeto descentralizado.

A primeira limitação do MCA Tradicional corrigida pelo MCA GVF, é a inicialização fora do objeto com concavidades, conforme é mostrado na Figura 2.13(a). As Figuras 2.13(b) e 2.13(c) demonstram iterações sucessivas e o resultado da segmentação obtido pelo MCA GVF é apresentado na Figura 2.13(d).




Figura 2.13: primeira limitação do MCA Tradicional superada pelo MCA GVF: a) inicialização da curva, b) e c) iterações intermediárias d) resultado final da segmentação.

Analisando o resultado da segmentação mostrada na Figura 2.13, percebe-se que o MCA GVF é eficaz na segmentação de objetos com concavidades quando inicializado fora do objeto.

Aplicando o MCA GVF visando superar a segunda limitação encontrada pelo MCA Tradicional, obtida quando a inicialização da curva é realizada dentro do objeto e afastada das suas bordas, conforme é ilustrado na Figura 2.14(a), obtêm-se as iterações intermediárias, apresentados nas Figuras 2.14(b) e 2.14(c), e o resultado final demonstrado na Figura 2.14(d).




Figura 2.14: segunda limitação do MCA Tradicional, corrigida pelo MCA GVF: a) inicialização da curva, b) e c) iterações intermediárias e d) resultado final da segmentação pelo MCA GVF.

Com base no resultado da segmentação mostrada na Figura 2.14, percebe-se que este método é eficaz na segmentação de objetos com concavidades dentro do objeto de forma centralizada.

Já considerando a limitação do método Balão para aplicar o MCA GVF, têm-se a inicialização da curva dentro do objeto, afastada das bordas e descentralizada, conforme é ilustrado na Figura 2.15(a). As iterações intermediárias obtidas a partir do MCA GVF são ilustrados nas Figuras 2.15(b) e 2.15(c), e o resultado final da segmentação é apresentado na Figura 2.15(d).




Figura 2.15: limitação dos MCAs Tradicional, Balão e GVF: a) inicialização da curva, b) e c) iterações intermediárias, e d) resultado final da segmentação pelo método GVF.

Analisando os resultados obtidos na Figura 2.15(d), percebe-se que a propagação do gradiente da imagem não garante que os pontos da curva detectem o objeto de interesse completo, apenas garante que a curva se desloca para a borda mais próxima de cada ponto da curva.

Deste modo, conclui-se que o MCA GVF resolve os problemas de inicialização afastada das bordas e da segmentação de regiões côncavas, mas somente quando inicializado fora do objeto. Já quando inicializado dentro do objeto, o resultado depende diretamente da inicialização da curva, principalmente em regiões côncavas. Além disto, constata-se também que outra limitação do GVF se dá em aplicações em tempo real, devido o fato deste método ser lento em relação aos métodos Tradicional e Balão (WILLIAMS; SHAM, 1992; MACKIEWICH, 1995; BOUHOURS, 2006). Isto ocorre por causa das iterações sucessivas realizadas para gerar o fluxo de vetores gradiente, que são custosas computacionalmente.

2.3 Estado da Arte

Diversas técnicas de segmentação são aplicadas para realizar a segmentação pulmonar. Dentre estas, destaca-se a combinação de limiarização, detecção de bordas, remoção do fundo da imagem e morfologia matemática (HU; HOFFMAN; REINHARDT, 2001; ANTONELLI; LAZZERINI; MARCELLONI, 2005; FELIX *et al.*, 2007)

e crescimento de região (SLUIMER; PROKOP; GINNEKEN, 2005; FELIX *et al.*, 2007). Porém, estes métodos apresentam resultados insuficientes e são adequados somente para casos específicos. Isto ocorre devido a segmentação de objetos ou estruturas em imagens médicas ser um processo que, em geral, é mais complexo comparado com a segmentação de outros tipos de imagens, devido à grande quantidade das formas de estruturas e/ou órgãos, especialmente na segmentação dos pulmões em imagens de TC. Outros fatos importantes são a possível existência de algum tipo de ruído, gerado no processo de aquisição de tais imagens, e de possíveis doenças que alteram as informações originais do órgão a ser segmentado (FELIX *et al.*, 2009).

Estudos utilizando MCAs abrangem diversas áreas médicas, tendo sido aplicados na segmentação de estruturas ou objetos em diversos tipos de imagens médicas, podendo ser citadas: segmentação do coração em imagens de ressonância magnética (PLUEMPITIWIRIYAWAJ; SOTTHIVIRAT, 2005), segmentação do cérebro em imagens de ressonância magnética (LIANG, 2008; SOUZA, 2003; HADZIAVDIC, 2000), segmentação do coração em imagens de ultrassom (TAUBER; BATATIA; AYACHE, 2005; LI; ACTON, 2007), segmentação de abdomens em imagens de TC (SHEN; KASSIM, 2007) e na segmentação dos pulmões em imagens de TC (ITAI; KIM; ISHIKAWA, 2007).

O trabalho desenvolvido por Itai, Kim e Ishikawa (ITAI; KIM; ISHIKAWA, 2007) aplica um MCA semelhante ao método Balão, possuindo uma energia interna que tende a expandir a área da curva e uma energia externa baseada no gradiente da imagem. Neste trabalho, a inicialização é realizada através da aplicação de um limiar baseado nas densidades radiológicas internas do pulmão mensuradas em UH. Para que a segmentação seja satisfatória com este método é necessário que a curva seja inicializada perto das bordas, o que não ocorre quando as densidades radiológicas internas do pulmão não possuem os valores descritos na literatura. Isto pode acontecer por diversos fatores, seja por ruído na aquisição da imagem, seja por doenças presentes no órgão, ou por falta de distinção entre o ar dentro dos pulmões e fora do corpo na imagem de TC, confundindo o método de inicialização.

Capítulo seguinte demonstra estas e outras limitações dos métodos estudados. Além disto, com base na fundamentação teórica e no estado da arte discutidos, um novo MCA é proposto, visando superar as limitações dos MCAs Balão e GVF.

Capítulo 3

METODOLOGIA

Neste Capítulo são apresentadas a forma de aquisição de imagens digitais através de Tomografia Computadorizada, os MCAs estudados são aplicados na segmentação dos pulmões em imagens de TC e suas limitações são discutidas. Por fim, um novo MCA é proposto buscando suprir tais limitações.

3.1 Aquisição de Imagens

Antes da aquisição das imagens, o tomógrafo é calibrado para a densidade de ar -1000 UH. A Calibração é realizada em período inferior a três meses da realização dos exames, conforme especificação técnica recomendada pelo fabricante (TOSHIBA, 1997). Ainda é realizado, antes da aquisição, um corte tomográfico com o *phantom* de água, cuja densidade já é conhecida para análise e controle de parâmetro pelo do sistema (FORTALEZA, 2006; WINKELER, 2006).

São utilizadas neste processo de aquisição de imagens dois tipos de tomografia computadorizada, TC com multidetectors e de TC de Alta Resolução (TCAR). As imagens obtidas utilizando TC com multidetectors são adquiridas por um tomógrafo GE MEDICAL SYSTEMS modelo LightSpeed16, enquanto as imagens de TCAR são adquiridas em um tomógrafo Toshiba modelo Auklet. As imagens de TCAR dos pulmões são adquiridas sob as seguintes condições: os cortes possuem colimação (espessura da fatia) de $1,5$ mm, campo de visão de 312 mm, voltagem do tubo de 120 kv, corrente elétrica do tubo de 200 mA, ajuste da janela pulmonar: centro e largura, respectivamente de $-600/1600$ UH, a dimensão da imagem reconstruída é de 512×512 pixels, e *voxel* com dimensões $0,585 \times 0,585 \times 1,5$

mm. As imagens são quantificadas em 16 *bits* e armazenadas no padrão DICOM (*Digital Imaging and Communications in Medicine*) (FORTALEZA, 2006; WINKELER, 2006).

As imagens são obtidas a partir de voluntários sadios e de pacientes com DPOC, sendo que as imagens de voluntários sadios são obtidos a partir de ambos os tomógrafos utilizados e as imagens de pacientes com DPOC somente com a TCAR. Na aquisição destas imagens, os cortes tomográficos são realizados na posição supina, considerando 3 regiões ao nível de: ápice, hilo e base (FORTALEZA, 2006; WINKELER, 2006).

Para a leitura destas imagens, que estão no formato DICOM, é utilizada a biblioteca livre DCMTK (*Dicom ToolKit*) fornecida pela OFFIS. Esta biblioteca é compatível com a linguagem de programação C++, a mesma utilizada no desenvolvimento deste trabalho.

São mostradas na Figura 3.1 dois exemplos de imagens, uma utilizando TC com multidetectores e uma obtida por TCAR. Estas imagens baseiam-se no princípio: cada estrutura interna do corpo humano possui um determinado valor de densidade radiológica, expresso em Unidades Hounsfield. Portanto, as faixas de densidade pulmonar adotadas neste trabalho são: área hiperaeradas ou hiperdistendida (-1000 a -950 UH), normalmente aerada (-950 a -500 UH), pouco aerada (-500 a -100 UH), não aerada (-100 a 100 UH) e região ossea (600 a 2000 UH) (GEVENOIS; YERNAULT, 1995; VIEIRA *et al.*, 1998; FÉLIX, 2007).

A distribuição destas faixas de densidade são mostradas nas Figuras 3.1(b) e 3.1(d), em que a cor vermelho representa regiões hiper-aerada, azul escuro normalmente aerada, azul claro representa as áreas pouco aeradas, preto não aerada, verde osso, e branco áreas não classificadas.

Contata-se que as imagens obtidas a partir da TC com multidetectores não possuem ruído, obedecendo as densidades radiológicas conforme é mostrado na Figura 3.1(b). Do mesmo modo, percebe-se que as imagens obtidas a partir do TCAR possuem ruídos gerados por uma fuga de corrente, detectada após a aquisição das imagens, demonstrada na Figura 3.1(d), em que as densidades radiológicas não obedecem ao padrão estabelecido. Este ruído distorce as faixas de densidades de alguns *voxels* da imagem, como pode ser observado na Figura 3.1(d). Além disso, aumenta de modo significativo as áreas não classificadas, identificadas pela cor branca.




Figura 3.1: imagem de TC dos pulmões: a) obtida com TC multidetectora, b) representação das faixas de densidades sem ruído, c) obtida a partir da TCAR e d) representação das faixas de densidades com ruído.

Com base nos problemas relatados anteriormente, podem-se apresentar as limitações, quanto ao processo de segmentações dos pulmões, dos MCAs estudados.

3.2 Limitações dos MCAs Tradicional, Balão e GVF na segmentação dos pulmões em imagens de TC

Após demonstrar os MCAs Tradicional, Balão e GVF é possível avaliar o desempenho de cada um na segmentação de imagens de TC dos pulmões.

Neste processo de segmentação, a primeira limitação encontrada é a inicialização da curva fora dos pulmões, devido a quantidade de formas possíveis dos pulmões, conforme é mostrado na Figura 3.2. Além disto, existe a presença de ar dentro e

fora dos pulmões nas regiões superior e inferior da imagem, confundindo com as estruturas dos pulmões, conforme é mostrado na Figura 3.1(b). O ruído também pode alterar as densidades radiológicas dos pulmões, conforme é demonstrado na Figura 3.1(d). Assim, a inicialização da curva dentro dos pulmões próximo das bordas e fora dos pulmões é inviável, impossibilitando a segmentação dos pulmões em imagens de TC utilizando o MCA Tradicional.




Figura 3.2: exemplos de imagens de TC do pulmão nas posições: a) base obtida por TCAR, b) base obtida através de TC com multidetectores e c) ápice.

Com base nas restrições apresentadas, restam os MCAs Balão e GVF, que visam resolver o problema de inicialização da curva. Para avaliar estes métodos, é usado uma imagem de TC do pulmão tida como regular, ou seja, que possui uma forma com poucos detalhes e menos estruturas pulmonares (vasos, vias aéreas, etc), conforme é ilustrado na Figura 3.2(a). Isto é usado para demonstrar a ineficácia destes métodos, mesmo em imagens regulares quando inicializados internamente.

Utilizando a Figura 3.2(a) para aplicar os métodos Balão e GVF, é segmentado apenas o pulmão esquerdo para testar os métodos. Deste modo, a Figura 3.3 demonstra o processo de conformação do *snake* utilizando os MCAs Balão e GVF, respectivamente para as Figuras 3.3(c) e 3.3(d).

Constata-se, por observar a Figura 3.3, a ineficácia deste método na segmentação do pulmão quando inicializado afastado das bordas. Isto ocorre devido ao fato de que este método utiliza como energia externa, as energias tradicionais sugeridas por Kass, Witkin e Terzopoulos (KASS; WITKIN; TERZOPOULOS., 1987). Esta energia atrai a curva até a borda do objeto, mas o problema é que esta não distingue os objetos a serem segmentados. Sendo assim, a curva é atraída para as bordas das estruturas internas do pulmão. Para demonstrar isto, na Figura 3.4 é mostrado a energia externa do MCA Tradicional, o gradiente da imagem.




Figura 3.3: imagens de TC do pulmão com: a) e c) inicialização do método Balão e GVF, respectivamente, b) e d) resultado final para os respectivos métodos.

O MCA Balão utiliza o mesmo gradiente do método Tradicional, resultando na detecção errada das bordas, pois as estruturas internas do pulmão estabilizam a curva, devendo acontecer apenas quando este encontra as bordas do pulmão, conforme é ilustrado na Figura 3.4(b).

Já o método GVF, expande todas as bordas encontradas, inclusive as bordas erradas (estruturas internas do pulmão), propagando o erro encontrado oriundo do operador Sobel, conforme é mostrado na Figura 3.4(c), obtida utilizando μ igual a 0,1 e com 400 iterações.

Diante da análise resultante da aplicação dos MCAs Tradicional, Balão e GVF, conclui-se que estes métodos, que utilizam como energia externa algum tipo de gradiente tradicional, são ineficazes na segmentação pulmonar. Isto porque estes métodos detectam apenas as bordas presentes na imagem, sem distinguir estruturas internas de paredes pulmonares, gerando falsas bordas dos objetos de interesse.




Figura 3.4: imagens de TC dos pulmões: a) original e b) gradiente Sobel, c) vetor de fluxo gradiente com 400 iterações.

Resumindo, constata-se que a segmentação dos pulmões em imagens de TC possuem restrições devido aos seguintes fatores:

- ▶ ruídos na aquisição das imagens através da TCAR;
- ▶ problemas com a inicialização da curva, podendo ocorrer por quatro motivos; primeiro, as imagens adquiridas em cada paciente são distintas e possuem tamanho e posicionamento diferentes; segundo, a visualização de um órgão depende da posição do corte analisado, onde um órgão pode assumir diferentes tamanhos e formatos; terceiro, existe ar dentro e fora dos pulmões, dificultando a identificação das densidades radiológicas das regiões internas do pulmão; quarto, a espessura da fatia da imagem é relevante visto que a densidade é retirada da média dos valores presentes em uma fatia, e quanto maior esta fatia, maior a distorção ou imprecisão da densidade.
- ▶ problemas com a detecção de falsas bordas na imagem, o que ocorre devido à detecção de objetos que não são o alvo da segmentação.

3.3 Método proposto

O novo algoritmo, intitulado MCA Crisp, surge visando superar as limitações observadas na aplicação dos MCAs na segmentação dos pulmões em imagens de TC. É constatado na seção 3.2 que os MCAs analisados, ao serem inicializados afastados das bordas, estabilizam-se após minimizar sua energia nas bordas encontradas (mínimos locais). Entretanto, estas bordas não são exatamente as bordas pulmonares, mas de estruturas internas dos pulmões.

Para solucionar esse problema, o novo método MCA Crisp propõe uma inicialização automática do contorno dentro do pulmão e uma nova força externa a ser incorporada ao MCA Balão desenvolvido por Mackiewicz (MACKIEWICH, 1995). Isto porque este produz resultados promissores para o processo de segmentação dos pulmões em imagens de TC, quando inicializado afastado das bordas, até mesmo quando inicializado de forma descentralizado. Além disso, seu processamento é rápido comparado com o método GVF. Deste modo, a formulação matemática para o novo método é dada por

$$E_{Crisp}[c(s)] = w_{cont}F_{cont}[c(s)] + w_{bal}F_{bal}[c(s)] + w_{crisp}F_{crisp}[c(s)], \quad (3.1)$$

em que $F_{cont}[c(s)]$ é a força de continuidade, a mesma utilizada na seção 2.2.1, $F_{bal}[c(s)]$ é a Força Balão descrita por Mackiewicz (MACKIEWICH, 1995) e $F_{crisp}[c(s)]$ é a nova força proposta pelo método MCA Crisp. Os termos w_{cont} , w_{bal} e w_{crisp} são referentes aos pesos de cada força na composição da energia do MCA Crisp.

Essa nova força, presente no MCA Crisp, é baseada no conhecimento específico das densidades pulmonares obtidas em imagens de TC. Segundo Gevenois e Yernault (GEVENOIS; YERNAULT, 1995) e Vieira *et al.* (VIEIRA *et al.*, 1998), as estruturas pulmonares possuem valores específicos de densidade medidas em Unidades Housfield (UH). Deste modo, esta força identifica quais estruturas encontradas através do operador Sobel são as bordas do pulmão. Isto é possível analisando a vizinhança de cada borda encontrada utilizando as densidades radiológicas. Esta vizinhança deve ser proporcional ao ruído da imagem, ou seja, quanto maior o ruído, maior a dimensão da vizinhança. Nas imagens utilizadas neste trabalho, é utilizada uma vizinhança 9×9 , cujo resultados experimentais demonstram que uma vizinhança maior não gera diferença significativa nos resultados.

Para se determinar a intensidade da Força Crisp em todos os pontos da imagem, primeiramente é necessário estabelecer uma função para calcular os percentuais de cada umas das regiões presentes na imagem. Para isto, assume-se que existem um conjunto de 6 classes s_i , em que i varia de 0 a 5, na seguinte ordem: hiper-aerada, normalmente aerada, pouco aeradas, não aerada, osso e áreas não classificadas. A definição destas regiões é realizada de forma análoga à técnica de multilimiarização, definindo a faixa de cada região a partir dos limites inferior e superior de cada estrutura definidas na seção 3.1.

Neste sentido, considerando $D(x, y)$ uma matriz de densidades pulmonares, (x, y) as coordenadas nas quais a vizinhança é analisada, tem-se a função que determina a quantidade de pontos com densidades presente em cada classe s_i determinada por

$$f(x, y, s_i) = \sum_{l=-4}^4 \sum_{m=-4}^4 R(x-l, y-m) \quad (3.2)$$

no qual

$$R(x, y) = \begin{cases} 1, & \lim_{inf}(s_i) < D(x, y) < \lim_{sup}(s_i), \\ 0, & \text{caso contrário,} \end{cases} \quad (3.3)$$

em que $\lim_{inf}(s_i)$ e $\lim_{sup}(s_i)$ representam os limites inferior e superior da faixa de densidade, descrita em UH, para a classe s_i .

Ao calcular os percentuais de cada classe s_i , desconsidera-se a classe 5, visto que as áreas não classificadas não devem compor o cálculo, sendo esta a forma de ignorar o ruído presente na imagem. Logo, o percentual P_i de cada classe i é definido por

$$P_i = \frac{f(x, y, s_i)}{\sum_{j=0}^4 f(x, y, s_j)}. \quad (3.4)$$

Deste modo, considerando que o resultado do operador Sobel em uma matriz de densidades $D(x, y)$ seja uma matriz $S(x, y)$, tem-se que a força Crisp $F_{crisp}(x, y)$ é dada por

$$F_{crisp}(x, y) = \begin{cases} 0, & \text{para } P_3 < 0,2 \text{ e } P_4 < 0,15, \\ S(x, y), & \text{caso contrário.} \end{cases} \quad (3.5)$$

A aplicação desta equação define a Força Crisp F_{crisp} considerando o gradiente Sobel da imagem, conforme é demonstrado na Figura 3.5.

Analisando as Forças Crisp F_{crisp} mostradas nas Figuras 3.5(j), 3.5(k) e 3.5(l), percebe-se que as energias provenientes das estruturas internas dos pulmões, demonstradas em vermelho nas Figuras 3.5(g), 3.5(h) e 3.5(i), são excluídas, resultando em uma força externa apenas com informações das bordas dos pulmões. Neste sentido, para finalizar o MCA proposto faltam as etapas de inicialização da curva, adição e remoção de pontos da curva.

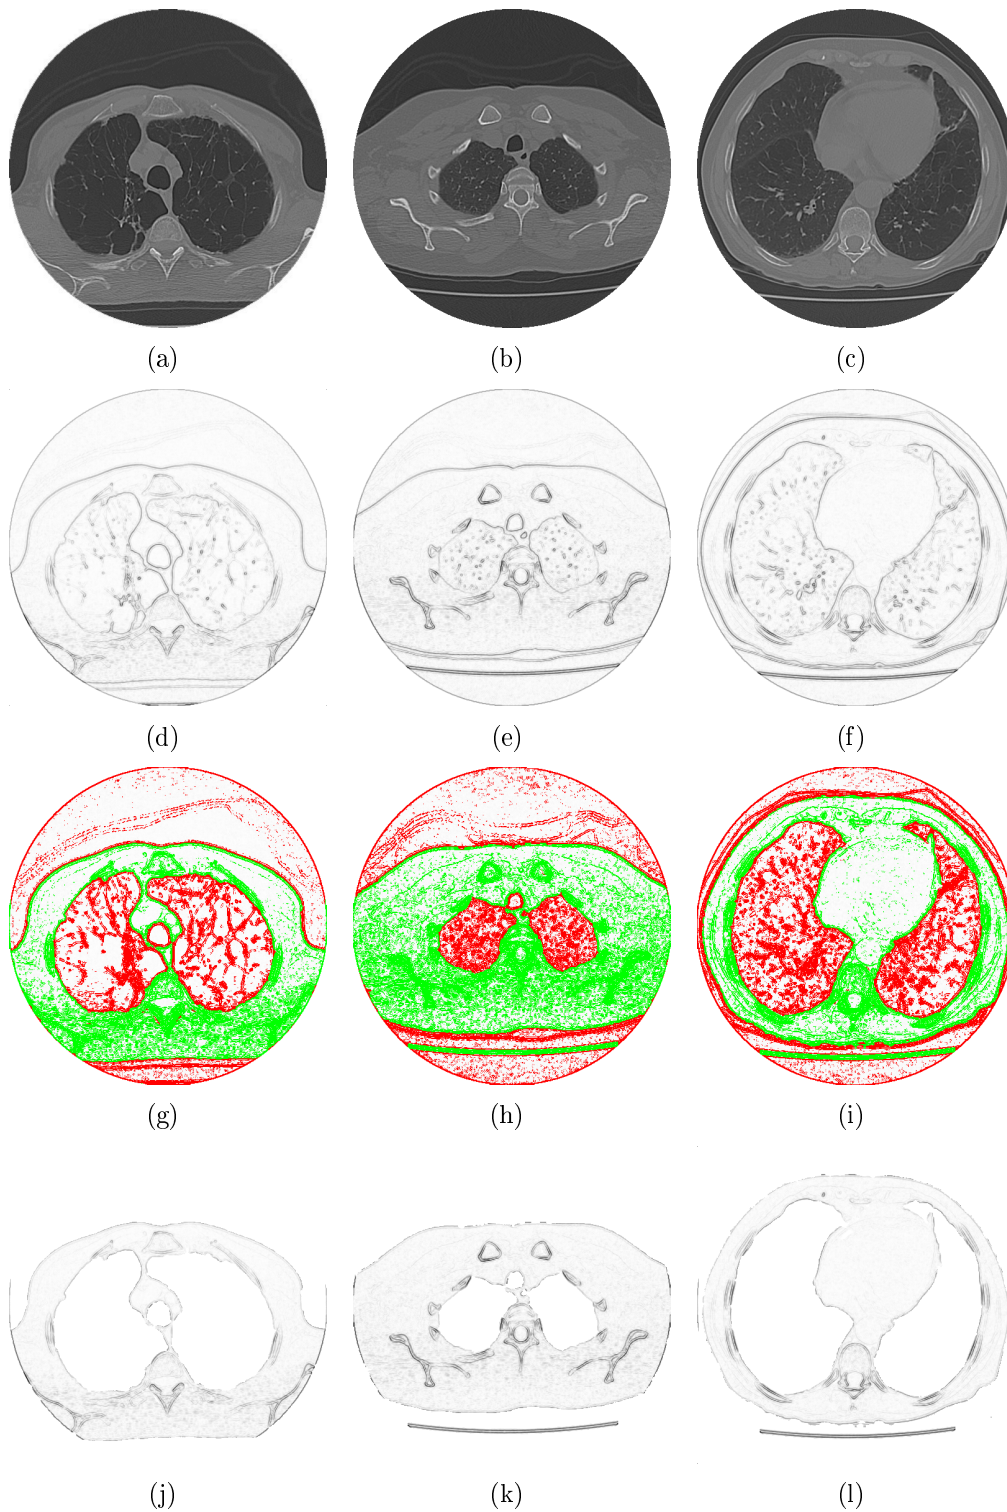


Figura 3.5: imagem de TC dos pulmões: a),b) e c) originais, d),e) e f) gradiente Sobel, g), h) e i) resultado da análise realizada pela força externa do método proposto, j), l) e m) força externa do método proposto.

3.4 Inicialização do Contorno

O algoritmo de inicialização do contorno tem como objetivo encontrar as coordenadas iniciais para este. No caso de imagens de TC dos pulmões, tem-se dois objetos de interesse, os pulmões direito e o esquerdo. Assim, têm-se um ponto de inicialização para cada pulmão, sendo o ponto de inicialização esquerdo *PIE* e o ponto de inicialização direito *PID*. Para se determinar as coordenadas do *PIE* e do *PID*, necessita-se de informação a priori. Analisando várias imagens de TC dos pulmões, observa-se que os objetos de interesse estão centralizados em duas regiões, conforme é ilustrado nas imagens de TC ilustradas na Figura 3.6.

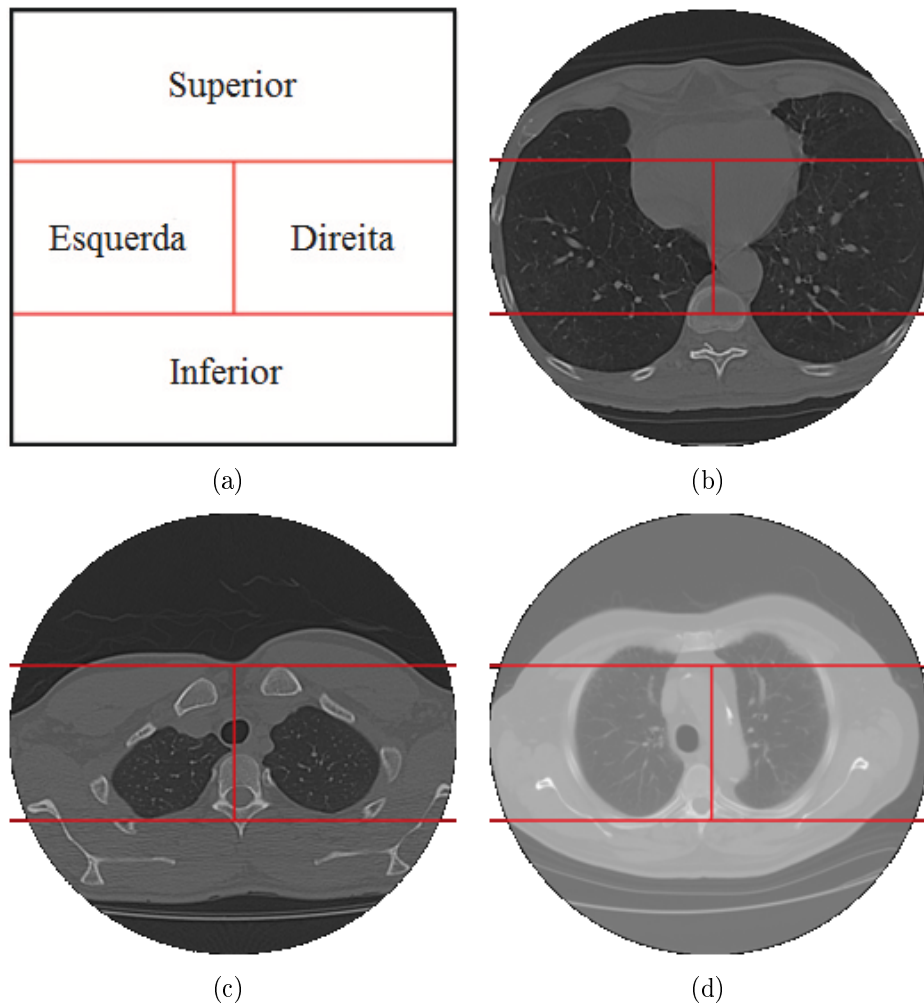


Figura 3.6: demonstração das regiões utilizadas para encontrar os pontos para as inicializações da curva nos pulmões esquerdo e direito.

Inicialmente, as imagens de TC são divididas em duas partes, a esquerda e a direita, em que são encontrados o *PIE* e o *PID*, porém as regiões superior e inferior,

ilustradas na Figura 4.1(a), confundiam o método de inicialização. Isto acontece devido a semelhança das densidades radiológicas, pois nestas regiões também existe ar. Sendo assim, estas duas regiões são excluídas da análise de inicialização, diminuindo o tempo de processamento e aumentando a taxa de acerto.

O primeiro passo para a inicialização é identificar as densidades radiológicas da região interna do objeto de interesse, que no caso estudado consistem nas áreas hiperaeradas, com densidades entre -1000 e -950 UH, e nas áreas normalmente aeradas, com densidades entre -950 e -500 UH. A Figura 3.1(b) ilustra a concentração destas duas densidades dentro do pulmão (azul e azul claro, respectivamente).

O segundo passo é limitar a região de inicialização, em que cada região possui limites nos eixos das abscissas e das ordenadas. No eixo das abscissas, o limite inferior e o superior são denominados LIX e LSX , respectivamente. Já no eixo das ordenadas, o limite inferior e superior são denominados LIY e LSY . Deste modo, considerando a matriz de *pixels* de uma imagem de TC $I(x, y)$ de dimensão 512×512 , calcula-se as coordenadas de inicialização no eixo das abscissas através da função

$$c(x) = \sum_{y=LIY}^{LSY} s(y) \quad \therefore \quad s(y) = \begin{cases} 1, & -1000 \text{ UH} < I(x, y) < -500 \text{ UH}, \\ 0, & \text{caso contrário.} \end{cases}, \quad (3.6)$$

em que a faixa de valores de entrada x da função $c(x)$ está situada entre LIX e LSX , e a posição x que obtiver o maior valor de saída da função $c(x)$ é dita como a coluna de inicialização da curva, ou seja, a coordenada x de inicialização, x_e para região Esquerda e x_d para região Direita.

Seguindo o mesmo princípio, para se calcular as coordenadas do eixo y dos pontos PIE e PID analisa-se as linhas pertencentes a cada região. A linha que obtiver a maior quantidade de *pixels* na faixa determinada (-1000 UH a -500 UH) é dita como coordenada de inicialização do eixo y para a região analisada, sendo y_e para a região esquerda e y_d para região direita. Deste modo, a função que determina a coordenada y de inicialização é

$$l(y) = \sum_{x=LIX}^{LSX} s(x) \quad \therefore \quad s(x) = \begin{cases} 1, & -1000 \text{ UH} < I(x, y) < -500 \text{ UH}, \\ 0, & \text{caso contrário.} \end{cases}, \quad (3.7)$$

em que os valores de entrada y da função $l(y)$ está entre LIX e LSY .

Após análise de diversas imagens, os valores que fornecem melhores resultados de inicialização para a região esquerda são 0 para LIX , 256 para LSX , 180 para LIY e 360 para LSY . Já para a região Direita, os valores que geram melhores resultados para inicialização são 256 para LIX , 512 para LSX , 180 para LIY e 360 para LSY . A região analisada considerando esses parâmetros está ilustrada Figura 3.7, em vermelho, assim como os pontos PIE e PID , encontrados a partir das equações 3.6 e 3.7, em amarelo. Estes pontos são utilizados como baricentro de um polígono regular. A distância de cada ponto para o baricentro é configurada no algoritmo de inicialização, juntamente com a quantidade de vértices do polígono. Deste modo, após testes exaustivos, é utilizado uma distância de 10 *pixels* entre cada ponto e o baricentro, e um total de 20 vértices, conforme é apresentado, em azul, na Figura 3.7.




Figura 3.7: demonstração das regiões utilizadas para encontrar os pontos para as inicializações dos contornos dos pulmões esquerdo e direito, em amarelo.

3.5 Adição e Remoção de pontos

A inclusão e exclusão de pontos também são elementos importantes na dinâmica do MCA Crisp. A inclusão permite um maior refinamento do *snake* e, portanto, maior acurácia na segmentação dos contornos de objetos. A exclusão elimina pontos do contorno que estavam em discrepância com os seus vizinhos e elimina pontos repetidos.

O método de adição de pontos se baseia na distância Euclidiana entre dois pontos consecutivos do contorno. Quando esta distância é maior do que uma distância máxima entre pontos, um novo ponto é adicionado entre estes, aumentando a sensibilidade do contorno. Com base na análise de diversas imagens, é adotado o valor de 5 *pixels* como distância máxima.

Já o método de remoção de pontos se baseia em dois critérios. O primeiro consiste em apagar o ponto quando suas coordenadas são iguais às coordenadas de um ponto consecutivo. O segundo critério baseia-se na remoção de pontos que possuem variação brusca de coordenadas em relação aos seus vizinhos. Esta variação é detectada a partir do ângulo formado entre o ponto analisado e seus vizinhos, como é demonstrado na Figura 3.8, em que A é o ponto analisado, B e C seus vizinhos e \hat{A} é o ângulo analisado.




Figura 3.8: figura para base do cálculo do ângulo entre três pontos.

Assim, aplicando a lei dos cossenos, o ângulo \hat{A} é calculado por

$$\hat{A} = \arccos\left(\frac{b^2 + c^2 - a^2}{2bc}\right), \quad (3.8)$$

em que a é o segmento de reta oposto ao ângulo \hat{A} , b e c os segmentos de reta adjacentes. Levando em consideração diversas imagens, é adotado o valor de 60° como ângulo mínimo. Deste modo, os pontos que possuem valor de ângulo menor do que este são excluídos.

Após apresentar o método proposto, é necessário verificar sua eficácia comparando com outros métodos e, principalmente, junto ao médico especialista na área de Pneumologia.

RESULTADOS E DISCUSSÕES

O método proposto é aplicado em imagens de TCAR e em imagens obtidas por TC com multidetectores. O banco de imagens de TCAR contém imagens de pacientes com DPOC e voluntários sadios, enquanto o de imagens de TC com multidetectores contém apenas imagens de voluntários sadios. Neste sentido, para avaliar a eficácia do MCA proposto, os resultados obtidos são divididos em três etapas: análise do algoritmo de inicialização, análise comparativa entre o MCA Crisp e os outros MCAs estudados e avaliação qualitativa pelo médico especialista.

4.1 Análise do algoritmo de inicialização

Na análise do algoritmo de inicialização é avaliada a eficácia do método de inicialização, visto que a curva deve ser inicializada dentro do pulmão. Quando o algoritmo inicializa a curva dentro dos pulmões, esta inicialização é dita satisfatória.

Nesta etapa de resultados, são utilizadas 50 imagens entre pacientes com DPOC e voluntários sadios, nas posições ápice, hilo e base obtidas a partir de imagens de TCAR e de TC com multidetectores, totalizando 100 segmentações de pulmões em imagens de TC, visto que cada imagem possui dois pulmões.

Algumas destas inicializações são mostradas na Figura 4.1, sendo as posições ápice, hilo e base demonstradas, respectivamente, nas Figura 4.1(a), 4.1(b) e 4.1(c) . Os resultados obtidos com esta inicialização nas imagens estudadas são considerados satisfatórios, visto que todas as curvas são inicializados dentro dos pulmões corretamente.




Figura 4.1: exemplos de resultados do algoritmo de inicialização da curva em imagens de TC dos pulmões.

4.2 Análise comparativa entre os MCAs Crisp, Balão e GVF

Para a análise comparativa entre os MCAs estudados e o Crisp, resultados para diferentes imagens são apresentados, duas de pacientes com DPOC, demonstradas pelas Figuras Figuras 4.2(a) e 4.2(b), e duas de voluntários saudáveis, sendo que uma de TCAR e outra de TC com multidetectores demonstradas nas Figuras 4.2(c) e 4.2(d), respectivamente. Entretanto, todo o conjunto de imagens é testado. A inicialização para todos os MCAs é a mesma, conforme é mostrado na primeira linha de cima para baixo da Figura 4.2.

Os resultados obtidos pelos MCAs Balão e GVF são demonstrados na segunda e terceira linha da Figura 4.2. Neste caso, verifica-se a ineficácia destes métodos




Figura 4.2: imagem de TC dos pulmões: a), b), c) d) inicialização da curva, em vermelho, resultados da segmentação aplicando e), f), g) e h) MCA Balão, i), j), l) e m) MCA GVF, n), o), p) e q) MCA Crisp.

na segmentação dos pulmões em imagens de TC. Em contrapartida, os resultados obtidos utilizando o método proposto revelaram-se eficazes na segmentação pulmonar, conforme é demonstrado na quarta linha da Figura 4.2.

Analisando os resultados descritos na Figura 4.2, percebe-se a eficácia do método proposto na segmentação dos pulmões em imagens de TC, considerando imagens com

e sem ruído, e também pulmões com diversas áreas e tamanhos. Por outro lado, os métodos Tradicional, GVF e Balão não obtêm o mesmo desempenho.

4.3 Avaliação Qualitativa do Médico especialista

A avaliação adotada neste trabalho baseia-se na avaliação qualitativa de segmentação descrita por Gonzales e Woods (GONZALEZ; WOODS, 2008). Deste modo, são consideradas 5 classes: ótimo, aceitável, razoável, ruim e péssimo. Esta classificação está descrita na Tabela 4.1.

Tabela 4.1: *método qualitativo de avaliação de segmentação de imagens*

Classificação	Descrição
Ótimo	altíssima qualidade, tão bom quanto se poderia desejar
Aceitável	qualidade aceitável, com a presença de pequenos erros
Razoável	média qualidade, com a presença de erros grosseiros
Ruim	possui apenas uma pequena parcela do objeto de interesse
Péssimo	ruim, não encontra parte nenhuma do objeto de interesse

Cada uma das classificações apresentadas na Tabela 4.1 é exemplificada na Figura 4.3. Deste modo, na Figura 4.3(a) é mostrada uma imagem de TC dos pulmões obtida na posição supina no nível de ápice, na Figura 4.3(b) está ilustrada uma segmentação ótima, em que os pulmões são segmentados sem falhas, seja por excesso ou por falta de regiões pulmonares. Na Figuras 4.3(c) é ilustrada uma segmentação aceitável, com pequenas falhas, em que parte do pulmão está fora da segmentação. Já na Figura 4.3(d) é ilustrada uma segmentação razoável, com erros grosseiros, em que uma parte considerável do pulmão está fora da região segmentada. Na Figura 4.3(e) é mostrada uma segmentação ruim, identificando apenas uma parte das paredes pulmonares, faltando grande parte do pulmão. Na Figura 4.3(f) é visualizada uma segmentação classificada como péssima, totalmente errada, sem identificar o pulmão corretamente.

Seguindo o critério de avaliação estabelecido, pode-se constatar que os resultados obtidos pelos métodos Balão e GVF obtêm segmentação ruim em todos os casos analisados na Figura 4.2. Já o método proposto obteve segmentações ótimas para as mesmas imagens.




Figura 4.3: exemplo de avaliação qualitativa de segmentação dos pulmões em imagens de TC: a) imagem original, b) segmentação ótima, c) segmentação aceitável, d) segmentação razoável, e) segmentação ruim e f) segmentação péssima.

Com o intuito de classificar o método proposto adequadamente, a avaliação dos resultados deste é realizada junto a um médico especialista na área da Pneumologia do Hospital Universitário Walter Cantídio da Universidade Federal do Ceará. Nesta etapa, são utilizadas 50 imagens entre pacientes com DPOC e voluntários sadios obtidas a partir de TCAR, totalizando 100 segmentações de pulmão em imagens de TC. Estas imagens foram adquiridas na posição supina, em que 20 são a nível de ápice, 15 a nível do hilo e 15 a nível de base. Na Tabela 4.2 é mostrado o resultado da avaliação realizada pelo médico especialista em cada nível separadamente e, em seguida, a análise geral obtida.

Com base nos resultados apresentados na Tabela 4.2, constata-se que a nível de ápice 95% das segmentações são consideradas ótimas pelo médico especialista, e os 5% restantes possuem pequenos erros de segmentação, sendo considerados como segmentações aceitáveis. Dentre estas segmentações, as Figuras 4.4(a) e 4.4(b) demonstram exemplos de segmentação ótima e aceitáveis a nível de ápice, respectivamente.

Tabela 4.2: *Resumo da avaliação qualitativa da segmentação do método proposto*

Nível de Corte	Total de pulmões	Ótimo	Aceitável	Razoável	Ruim	Péssimo
Ápice	40	38	2	0	0	0
Base	30	19	11	0	0	0
Hilo	30	0	23	7	0	0
Geral	100	57	36	7	0	0

Os resultados obtidos a partir do nível de base encontrados na Tabela 4.2, mostram que o método proposto obtém 63,4% de segmentações ótimas e 36,6% com pequenos erros, sendo considerados aceitáveis. Exemplos destes resultados de segmentação à nível de ápice são ilustrados nas Figuras 4.4(c) e 4.4(d).

Constata-se também que a nível de hilo não existe nenhuma segmentação ótima, devido o fato de que as segmentações possuem erros, sendo 76,6% pequenos erros e 23,4% erros grosseiros, sendo exemplos destes demonstrados nas Figuras 4.4(e) e 4.4(f).

Considerando todas as imagens analisadas, constata-se que 57% das imagens analisadas obtém segmentações ótimas, 36% segmentações aceitáveis e 7% obtiveram segmentações razoáveis.

Para demonstrar a limitação encontrada pelo método proposto, as energias envolvidas neste método são plotadas em uma mesma imagem, considerando apenas o pulmão esquerdo, conforme é mostrado na Figura 4.5. Deste modo, as Figuras 4.5(b), 4.5(e) e 4.5(h) demonstram as energias do contorno em imagens com erros de segmentação a nível de ápice, hilo e base, respectivamente.

Consideram-se que as Figuras 4.5(b), 4.5(e) e 4.5(h) mostram a Força Balão como um fluxo que inicia com o maior valor no centróide do contorno, ilustrado por um ponto cinza. As cores vermelho, amarelo, verde e azul, em ordem decrescente, demonstram a intensidade da Força Balão diminuindo a medida que a distância do centróide aumenta. A Força Balão é plotada nestas imagens apenas nos pontos da imagem em que a Força Crisp detecta regiões homogêneas, sem bordas pulmonares. Os pontos da imagem que possuem bordas pulmonares, mostram a própria Força Crisp. A Força de Continuidade não está mostrada na imagem por não influenciar no erro gerado, visto que esta somente tende a manter a curva equidistante.




Figura 4.4: exemplos de segmentações dos pulmões em imagens de TC pelo método proposto a nível de: a) e b) ápice, c) e d) base, e) e f) hilo.

Com base nos resultados das segmentações ilustradas, em vermelho, nas Figuras 4.5(c), 4.5(f) e 4.5(i) e comparando com as respectivas energias plotadas nas Figuras 4.5(b), 4.5(e) e 4.5(h), conclui-se que a Força Balão desloca o contorno afastando-o do centróide, isto acontece por iterações sucessivas, até o contorno




Figura 4.5: análise de erros encontrados na segmentação do pulmão esquerdo em imagens de TC: a nível de ápice a) imagem original, b) energia crisp e balão da imagem e c) segmentação errônea; a nível de hilo d) imagem original, e) energia crisp e balão da imagem e f) segmentação errônea; a nível de base g) imagem original, h) energia crisp e balão da imagem e i) segmentação errônea.

detectar uma energia externa menor, que é a parede pulmonar. Considerando o fluxo da Força Balão, percebe-se que as regiões pulmonares que faltam nas segmentações encontradas, partindo do centróide, localizam-se depois de uma energia externa já detectada, fazendo com que os pontos do contorno se estabilizem sem alcançar estas regiões, gerando erros de segmentação. Esta falha é ocasionada pela limitação da Força Balão citada anteriormente.

Após apresentar o método proposto, demonstrar suas vantagens em relação aos outros MCAs, avaliar qualitativamente os resultados das segmentações obtidas junto a um médico especialista e apresentar as limitações ainda encontradas pelo método, é possível retirar conclusões sobre este método, descrever suas contribuições e apresentar trabalhos futuros para aperfeiçoá-lo.

Capítulo 5

CONCLUSÕES, CONTRIBUIÇÕES E TRABALHOS FUTUROS

Esta dissertação propõe um Método de Contorno Ativo, denominado de MCA Crisp, para a segmentação automática dos pulmões em imagens de TC. Realiza também uma comparação com os MCAs Tradicional, GVF e Balão, utilizando, para isto, um conjunto de imagens de Tomografia Computadorizada. São usadas imagens de TCAR de voluntários saudáveis e pacientes com DPOC e imagens de TC com multidetectores de voluntários sadios, dentre as quais as imagens de TCAR são ruidosas.

As segmentações obtidas pelo método proposto foram avaliadas por um médico especialista do Hospital Universitário Walter Cantídio, obtendo 57% de segmentações ótimas, 36% de segmentações aceitáveis e 7% obtiveram segmentações razoáveis, não gerando segmentações ruins ou péssimas. Deste modo, pode-se dizer que 93% dos resultados obtidos com o MCA Crisp das segmentações obtém resultados satisfatórios, em que não apresentaram erros ou tiveram erros pequenos, que podem ser corrigidos manualmente pelo próprio médico. Entretanto, os MCAs Tradicional, Balão e GVF apresenta resultados insatisfatórios, obtendo segmentações ruins em todos os pulmões.

Estas segmentações são analisadas em três níveis de corte: ápice, hilo e base. O nível de corte que obtém melhores resultados é o nível de ápice, com 95% de segmentações ótimas e 5% de segmentações aceitáveis. Isto acontece devido o fato dos pulmões neste nível não possuírem muitas concavidades. Já o nível de corte que

obteve os piores resultados é o hilo, com 76,6% de segmentações com pequenos erros e 23,4% com erros grosseiros. Isto acontece devido a irregularidade no formato dos pulmões, com diversos tipos de concavidades neste nível.

Desta forma, pode-se afirmar que o Método de Contorno Ativo Crisp é um algoritmo útil para a segmentação dos pulmões, podendo ser integrado a sistemas que auxiliem o diagnóstico médico, visto que segmenta de forma automática e satisfatória os pulmões em imagens de TC. O que diminui o tempo de análise do médico, pois até nas imagens que obtém erros de segmentação é possível corrigir alguns pontos manualmente, sem a necessidade de fazer a segmentação completa, que é uma operação enfadonha e cansativa.

Diversas contribuições são apresentadas neste método, cuja a principal é a nova energia externa do método que distingue as bordas das estruturas internas do pulmão das bordas pulmonares. Isto é possível pela análise da vizinhança de cada borda, em que este método determina uma vizinhança ótima de 9×9 para esta análise, funcionando até em imagens ruidosas.

Outra contribuição é o método de inicialização, obtendo resultados satisfatórios, inclusive em imagens ruidosas. Além disto, este método descreve métodos de adição e remoção de pontos do contorno, o que não é descrito na literatura nos outros métodos.

A perspectiva nos trabalhos futuros está voltada para dois pontos principais: melhoria da interpretação das falsas bordas pulmonares e estudo de técnicas que auxiliem o contorno a segmentar regiões côncavas quando o contorno é inicializado internamente de forma descentralizada, podendo ser descritas as seguintes melhorias:

- ▶ desenvolver uma energia externa baseada em Inteligência Computacional, aplicando Redes Neurais Artificiais ou Lógica Nebulosa, visto que algumas bordas pulmonares não possuem padrões óbvios;
- ▶ desenvolver uma energia interna capaz de segmentar regiões côncavas mesmo quando inicializado internamente de forma descentralizada;
- ▶ desenvolver novos métodos de inicialização para aumentar a eficiência do método;
- ▶ desenvolver outras formas de adição e remoção de pontos utilizando Inteligência Computacional para evitar que pontos sejam adicionados fora do

pulmão.

Espera-se que com estas melhorias, os resultados futuros sejam ainda mais precisos e rápidos, comparados com os obtidos neste trabalho.

Referências Bibliográficas

ALBUQUERQUE, V. H. *Análise de microfotografias e quantificação através de um sistema em redes neurais artificiais*. Dissertação (Mestrado) — Centro Federal de Educação Tecnológica do Ceará, março 2006.

ALBUQUERQUE, V. H. C. de; TAVARES, J.; FILHO, P. P. R. Medição automática da dureza brinell utilizando técnicas de processamento e análise de imagem. *5º Congresso Luso-Moçambicano de Engenharia*, Maputo - Angola, 2008.

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

AMINI, A.; WEYMOUTH, T.; JAIN, R. C. Using dynamic programming for solving variational problems in vision. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 12, p. 855–867, 1990.

ANTONELLI, M.; LAZZERINI, B.; MARCELLONI, F. Segmentation and reconstruction of the lung volume segmentation and reconstruction of the lung volume. *ACM Symposium on Applied Computing*, Santa Fe, New Mexico, USA., p. 255–259, março 2005.

BERNSEN, J. Dynamic thresholding of gray-level images. *Proc. Eighth International Conference on Pattern Recognition*, Paris, p. 1251–1255, outubro 1986.

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

CARO, A. *et al.* *Potential Fields as an External Force and Algorithmic Improvements in Deformable Models*. [S.l.]: Electronic Letters on Computer Vision and Image Analysis, 2003. (25-36).

CELLI, B.; MACNEE, W. Standards for the diagnosis and treatment of patients with copd: a summary of the ats/ers position paper. *European Respiratory Journal*, v. 23, p. 932–946, 2004.

CHEN, Q. *et al.* Parametric active contours for object tracking based on matching degree image of object contour points. *Pattern Recognition Letters*, v. 29, p. 126–141, 2006.

COCQUEREZ, J. P.; PHILLIP, S. *Analyse d'images: filtrage et segmentation*. Masson, France, p. 240–245, 1995.

COHEN, L. D. On active contour models and balloons. *CVGIV: Image Understanding*, v. 53, p. 211–218, March 1991.

COSTA, L. H. L. *Desenvolvimento de um sistema semi-automático para determinação de durezas Brinell e Vickers utilizando técnicas de processamento e análise de imagem*. Dissertação (Mestrado) — Centro Federal de Educação Tecnológica do Ceará, 2008.

DOI, K. Overview on research and development of computer-aided diagnostic schemes. *Semin Ultrasound CT MR*, v. 25, n. 5, p. 404–410, 2004.

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

FELIX, J. H. S. *et al.* Lung and chest wall structures segmentation in ct images. *VIPMAGE-aceito*, outubro 2007.

FELIX, J. H. S. *et al.* Avaliação computacional de enfisema pulmonar em tc: comparação entre um sistema desenvolvido localmente e um sistema de uso livre. *Jornal Brasileiro de Pneumologia*, v. 35, n. 9, 2009.

FORTALEZA, S. C. B. *Efeitos da Administração de Pressão Positiva Contínua em Vias Aéreas de Modo não Invasivo Sobre a Aeração do Parênquima Pulmonar em*

Pacientes com Doença Pulmonar Obstrutiva Crônica. Dissertação (Mestrado) — Universidade Federal do Ceará, Fortaleza, 2006.

GEVENOIS, P. A.; YERNAULT, J. C. Can computed tomography quantify pulmonary emphysema. *European Respiratory Journal*, n. 5, p. 843–848, janeiro 1995.

GONZALEZ, R. C.; WOODS, R. *Digital Image Processing*. 3a. ed. New Jersey: Pearson Prentice Hall, 2008. ISBN 0-13-168728-x.

HADZIAVDIC, V. *A Comparative Study of Active Contour Models for Boundary Detection in Brain Images*. Dissertação (Mestrado) — Faculty for Mathematical and Natural Sciences, Universidade da Alemanha, 2000.

HOUNSFIELD, G. N. Computerized transverse axial scanning (tomography): Part 1. description of system. *British Journal of Radiology*, v. 46, p. 1016–1022, 1973.

HU, S.; HOFFMAN, E. A.; REINHARDT, J. M. Automatic lung segmentation for accurate quantitation of volumetric x-ray ct images. *IEEE Transactions on Medical Imaging*, v. 20, n. 6, p. 490–498, junho 2001.

ITAI, Y.; KIM, H.; ISHIKAWA, S. A segmentation method of lung areas by using snakes and automatic detection of abnormal shadow on the areas. *International Journal of Innovative Computing Information and Control*, v. 3, n. 2, p. 277–284, abril 2007.

ITAI, Y. *et al.* Automatic segmentation of lung areas based on snakes and extraction of abnormal areas. *Proceedings of the 17th IEEE International Conference on Tools with Artificial Intelligence (ICTAI05)*, 2005.

JARDIM, J. R.; OLIVEIRA, J. A. de; NASCIMENTO, O. Revisão de alguns aspectos de epidemiologia e tratamento da doença estavel. *Sociedade brasileira de pneumologia e fisiologia*, 2006.

JOHANNSEN, G.; BILLE, J. A threshold selection method using information measures. Munique, Alemanha, p. 140–143, 1982.

JÚNIOR, O. S. de S. *Método de Reconhecimento pessoal através da íris usando funções geoestatísticas*. Dissertação (Mestrado) — Universidade Federal do Maranhão, 2006.

KAK, A. C.; SLANEY, M. *Principles of Computerized Tomographic Imaging*. New York,: IEEE Engineering in Medicine and Biology Society, 1999. ISBN O-87942-198-3.

KASS, M.; WITKIN, A.; TERZOPOULOS., D. Snakes:active contours models. *International Journal of Computer Vision*, v. 1, 1987.

LI, B.; ACTON, S. T. Active contour external force using vector field convolution for image segmentation. *IEEE TRANSACTIONS ON IMAGE PROCESSING*, v. 16, n. 8, p. 2096 – 2106, August 2007.

LI, C.; LIU, J.; FOX, M. D. Segmentation of edge preserving gradient vector flow: An approach toward automatically initializing and aplitting of snakes. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2005.

LIANG, L. Segmentation of the left ventricle from cardiac mr images based on radial gvf snake. *International Conference on BioMedical Engineering and Informatics - BMEI*, v. 2, n. 1, p. 238 – 242, 2008.

LOPES, E. C. *Detecção de Faces e Características Faciais*. Dissertação (Mestrado) — Pontifícia Universidade Católica do Rio Grande do Sul, 2003.

LV, X.; GAO, X.; ZOU, H. Interactive curved planar reformation based on snake model. *Science Direct*, v. 32, n. 663-669, 2008.

MACKIEWICH, B. *Intracranial Boundary Detection and Radio Frequency Correction in Magnetic Resonance Images*. Dissertação (Mestrado) — School of Computing Science, 1995.

MCINERNEY, T.; TERZOPOULOS, D. Deformable models. *Medical Images Analysis: A Survey*, n. 91-108, 1996.

MELO, F. D. de. *Contornos Ativos Snakes para a Segmentação de Imagens Digitais*. Dissertação (Mestrado) — Faculdade de Informática de Presidente Prudente - SP, 2005.

NIXON, M. S.; AGUADO, A. S. *Feature Extraction and Image Processing*. 1. ed. Woburn, MA: Newnes, 2002. ISBN 0750650788.

PAPAMARKOS, N.; STROUTHOPOULOS, C.; ANDREADIS, I. Multithresholding of color and grey-level images through a neural network technique. *Image and Vision Computing*, v. 18, n. 213-222, 2000.

PICHUMANI, R. *Construction of A Three-Dimensional Geometric Model for Segmentation and Visualization of Cervical Spine Images*. Tese (Doutorado) — Medical Informatics of Stanford University, 1997.

PLUEMPITIWIRIYAWAJ, C.; SOTTHIVIRAT, S. Active contours with automatic initialization for myocardial perfusion analysis. *27th Annual International Conference of the Engineering in Medicine and Biology Society IEEE-EMBS*, p. 3332 – 3335, 2005.

SHEN, W.; KASSIM, A. A new scheme for automatic initialization of deformable models. *IEEE International Conference on Image Processing - ICIP*, v. 4, p. IV – 289 – 292., 2007.

SIEGWART, R.; NOURBAKHSI, I. *Introduction to Autonomous Mobile Robots*. [S.l.]: The MIT Press, 2004. ISBN 0-262-19502-X.

SILVA, J. S. S. da. *Segmentação Pulmonar em Estudos de Tomografia Axial Computorizada*. Dissertação (Mestrado) — Universidade de Aveiro, 2005.

SILVA, V. L. da Costa e; DAVID, A. *Building blocks for tobacco control: a handbook*. Geneva: [s.n.], 2004. World Health Organization.

SLUIMER, I.; PROKOP, M.; GINNEKEN, B. van. Toward automated segmentation of the pathological lung in ct. *IEEE Transactions on Medical Imaging*, v. 24, n. 8, p. 1025–1038, agosto 2005.

SONKA, M.; HLAVAC, V.; BOYLE, R. *Image Processing, Analysis, and Machine Vision*. [S.l.]: Chapman and Hall Computing, 2008.

SOUZA, A. M. de. *Identificação de Tumores Cerebrais por meio do Modelo de Contornos Ativos e Algoritmos Genéticos*. Dissertação (Mestrado) — Universidade Federal do Paraná, 2003.

TAUBER, C.; BATATIA; AYACHE. A general quasi-automatic initialization for snakes: application to ultrasound images. *IEEE International Conference on Image Processing*, v. 2, n. 1, p. II – 806 – 809, 2005.

TERZOPOULOS, D. *et al.* Elastically deformable models. *Computer Graphics*, v. 21, n. 4, p. 205–214, 1987.

TOSHIBA. *Manual de operação do sistema: tomógrafo computadorizado de raio-x para corpo inteiro: Aquisição de dados de calibração*. São Paulo, 1997.

VIEIRA, S. R. R. *et al.* A lung computed tomographic assessment of positive end-expiratory pressure-induced lung overdistension. *American Journal of Respiratory and Critical Care Medicine*, v. 158, p. 1571–1577, 1998.

WEBSTER, J. G. *Medical instrumentation application designer*. [S.l.]: USA: John Wiley and Sons Inc, 1998.

WILLIAMS, D.; SHAM, M. A fast algorithm for active contours and curvature. *Image Understanding*, 1992.

WINKELER, G. F. P. *Efeitos Agudos da Administração de Pressão Positiva Contínua em Vias Aéreas de Modo não Invasivo Sobre o Parênquima Pulmonar de Voluntários Sadios nas Posições Supina e Prona: Alterações na Tomografia Computadorizada de Alta Resolução*. Dissertação (Mestrado) — Univesidade Federal do Ceará, Fortaleza, 2006.

XU, C.; PRINCE, J. *Snakes, Shapes and Gradient Vector Flow*. 105 Barton Hall, Baltimore, MD 21218, April 1997.

ZAHARA, E.; FAN, S.-K. S.; TSAI, D.-M. Optimal multi-thresholding using a hybrid optimization approach. *Pattern Recognition Letters*, v. 26, n. 8, p. 1082–1095, June 2005.

Livros Grátis

(<http://www.livrosgratis.com.br>)

Milhares de Livros para Download:

[Baixar livros de Administração](#)

[Baixar livros de Agronomia](#)

[Baixar livros de Arquitetura](#)

[Baixar livros de Artes](#)

[Baixar livros de Astronomia](#)

[Baixar livros de Biologia Geral](#)

[Baixar livros de Ciência da Computação](#)

[Baixar livros de Ciência da Informação](#)

[Baixar livros de Ciência Política](#)

[Baixar livros de Ciências da Saúde](#)

[Baixar livros de Comunicação](#)

[Baixar livros do Conselho Nacional de Educação - CNE](#)

[Baixar livros de Defesa civil](#)

[Baixar livros de Direito](#)

[Baixar livros de Direitos humanos](#)

[Baixar livros de Economia](#)

[Baixar livros de Economia Doméstica](#)

[Baixar livros de Educação](#)

[Baixar livros de Educação - Trânsito](#)

[Baixar livros de Educação Física](#)

[Baixar livros de Engenharia Aeroespacial](#)

[Baixar livros de Farmácia](#)

[Baixar livros de Filosofia](#)

[Baixar livros de Física](#)

[Baixar livros de Geociências](#)

[Baixar livros de Geografia](#)

[Baixar livros de História](#)

[Baixar livros de Línguas](#)

[Baixar livros de Literatura](#)
[Baixar livros de Literatura de Cordel](#)
[Baixar livros de Literatura Infantil](#)
[Baixar livros de Matemática](#)
[Baixar livros de Medicina](#)
[Baixar livros de Medicina Veterinária](#)
[Baixar livros de Meio Ambiente](#)
[Baixar livros de Meteorologia](#)
[Baixar Monografias e TCC](#)
[Baixar livros Multidisciplinar](#)
[Baixar livros de Música](#)
[Baixar livros de Psicologia](#)
[Baixar livros de Química](#)
[Baixar livros de Saúde Coletiva](#)
[Baixar livros de Serviço Social](#)
[Baixar livros de Sociologia](#)
[Baixar livros de Teologia](#)
[Baixar livros de Trabalho](#)
[Baixar livros de Turismo](#)